

UNIVERSIDADE ESTADUAL PAULISTA “JULIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS DE BOTUCATU

**GEOESTATÍSTICA MULTIVARIADA NA DELIMITAÇÃO DE
ZONAS DE MANEJO NA CULTURA DE CANA-DE-AÇÚCAR**

ANDERSON ANTONIO DA CONCEIÇÃO SARTORI

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp – Câmpus de
Botucatu, para obtenção do título de Doutor
em Agronomia – Irrigação e Drenagem

BOTUCATU - SP

Dezembro – 2014

UNIVERSIDADE ESTADUAL PAULISTA “JULIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS DE BOTUCATU

**GEOESTATÍSTICA MULTIVARIADA NA DELIMITAÇÃO DE
ZONAS DE MANEJO NA CULTURA DE CANA-DE-AÇÚCAR**

ANDERSON ANTONIO DA CONCEIÇÃO SARTORI

Orientadora: Profa. Dra. Célia Regina Lopes Zimback

Co-orientador: Prof. Dr. Roberto Lyra Villas Bôas

Supervisora no exterior: Dra. Annamaria Castrignanò

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp – Câmpus de
Botucatu, para obtenção do título de Doutor
em Agronomia – Irrigação e Drenagem

BOTUCATU - SP

Dezembro – 2014

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO
DA INFORMAÇÃO - DIRETORIA TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP -
FCA - LAGEADO - BOTUCATU (SP)

S251g Sartori, Anderson Antonio da Conceição, 1980-
Geoestatística multivariada na delimitação de zonas de
manejo na cultura de cana-de-açúcar / Anderson Antonio da
Conceição Sartori. - Botucatu : [s.n.], 2014
xiii, 143 f. : ils. color., grafs., tabs.

Tese (Doutorado) - Universidade Estadual Paulista, Fa-
culdade de Ciências Agrônômicas, Botucatu, 2014
Orientador: Célia Regina Lopes Zimback
Coorientador: Roberto Lyra Villas Bôas
Inclui bibliografia

1. Cana-de-açúcar - Manejo. 2. Agricultura de precisão.
3. Sensoriamento remoto. 4. Análise multivariada. I. Zim-
back, Célia Regina Lopes. II. Villas Bôas, Roberto Lyra.
III. Universidade Estadual Paulista "Júlio de Mesquita Fi-
lho" (Campus de Botucatu). Faculdade de Ciências Agrônô-
micas. IV. Título.

UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

CERTIFICADO DE APROVAÇÃO

TÍTULO: GEOESTATÍSTICA MULTIVARIADA NA DELIMITAÇÃO DE ZONAS
DE MANEJO NA CULTURA DE CANA-DE-AÇÚCAR

ALUNO: ANDERSON ANTONIO DA CONCEIÇÃO SARTORI

ORIENTADOR: PROF. DR. CÉLIA REGINA LOPES ZIMBACK


Aprovado pela Comissão Examinadora


PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK


PROF. DR. PAULO MILTON BARBOSA LANDIM


PROF. DR. MARCELO DE ALMEIDA SILVA


PROFA. DRA. ALESSANDRA FAGIOLI DA SILVA


PROF. DR. EDNALDO CARVALHO GUIMARÃES

Data da Realização: 10 de dezembro de 2014.

À DEUS

As tarefas que Deus me dá para cumprir todos os dias são grandes, porém sei que o seu amor por mim é muito maior que qualquer uma delas, por isso sempre faço a minha parte com muito amor e dedicação.

As minhas amadas mães,
Ester Barbosa da Conceição e
Aparecida Barbosa da Conceição
deixo aqui a minha eterna gratidão por todo amor a
mim dedicado, pela paciência e apoio incondicional
para que tão longe eu pudesse chegar.

Aos meus primos “irmãos e sobrinhos”,
Anaceli Maria, Vitor Gabriel e Ana Luisa,
que muito contribuíram nesta fase da minha vida.

.....Dedico

AGRADECIMENTO ESPECIAL

À minha orientadora, Profa. Dra. **Célia Regina Lopes Zimback**, agradeço pelos ensinamentos, solidariedade, por ser atenciosa, correta, pela confiança em mim depositada e pela grande amizade que construímos. Suas palavras de incentivo e o grande empenho nas etapas da tese foram essenciais para a qualidade deste trabalho.

“Se não fosse imperador, desejaria ser professor. Não conheço missão maior e mais nobre que a de dirigir as inteligências jovens e preparar os homens do futuro”.

D. Pedro II

To **Dr. Annamaria Castrignanò** thank you for your guidance and supervision during my internship experience in Bari-Italy. I had a really great time working in your lab and getting enthusiasm of words.

AGRADECIMENTOS

À Faculdade de Ciências Agrônômicas/UNESP, Campus de Botucatu-SP, por meio da Coordenação do Programa de Pós-graduação em Agronomia-Irrigação e Drenagem, com conceituado corpo docente, estrutura física e por me abrir os caminhos do conhecimento científico e pelo crescimento pessoal e profissional.

À Agricultural Research Council Research (CRA-SCA) pela oportunidade do processamento dos dados e utilização do software ISATIS.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa “Programa Institucional de Doutorado Sanduiche no Exterior PDSE – Processo 99999.014305/2013-05”, que permitiram a realização desta tese.

Ao meu querido amigo Bruno pelo apoio e cuidado que me proporcionou durante este trabalho de estágio no exterior. Obrigado por fazer meus dias memoráveis!

Aos meus amigos e companheiros de estudos que diretamente ajudaram na coleta dos dados em campo e posteriormente em laboratório, Gabriel Llobet, Victor Leda, Vanessa Polonio e Diego Moraes pela sua companhia em Bari em momentos Lolikos.....

Aos membros da banca: Prof. Dr. Paulo Milton Barbosa Landim, Prof. Dr. Marcelo de Almeida Silva, Prof. Dr. Ednaldo Carvalho Guimarães e Prof. Dr. Alessandra Fagioli da Silva pela disponibilidade para avaliação deste trabalho e pelas importantes sugestões oferecidas.

Aos colegas do Grupo de Estudos e pesquisas Agrárias Georreferenciadas – GEPAG, que me proporcionaram anos de aprendizados, carinho e companheirismo, ensinando-me o quão maravilhoso é conviver com os amigos. E também o quanto é rico conviver com diversos estudiosos de diversas áreas.

Aos professores e funcionários do Departamento de Solos e Recursos Ambientais, pela agradável convivência e amizade.

Aos funcionários da biblioteca e às secretárias de Pós Graduação, pela atenção e dedicação ao longo destes anos.

Aos queridos professores e amigos que compartilharam comigo mais essa etapa de minha vida e que com seus conselhos, ideias e atitudes contribuíram para meu desenvolvimento pessoal e profissional.

A todos aqueles que contribuíram, direta ou indiretamente, para a realização deste trabalho.

A todos meus sinceros agradecimentos.

SUMÁRIO

	Páginas
AGRADECIMENTO ESPECIAL.....	IV
AGRADECIMENTOS	V
SUMÁRIO.....	VII
LISTA DE FIGURAS	IX
LISTA DE TABELAS	XIII
1 RESUMO	1
2 SUMMARY	3
3 INTRODUÇÃO.....	5
4 REVISÃO DE LITERATURA	8
4.1 A cultura da cana-de-açúcar e sua importância para o agronegócio brasileiro.....	8
4.2 Influência das variáveis ambientais e edáficas na produção da cana-de-açúcar.....	11
4.3 Sensoriamento Remoto na cultura da cana-de-açúcar	13
4.3.1 Propriedades de reflectância espectral no manejo das culturas.....	15
4.4 Análise geoestatística dos dados.....	18
4.4.1 Abordagem univariada	19
4.5 Abordagem multivariada	22
4.5.1 Delimitação das zonas específicas de manejo.....	24
4.5.2 Fusão de dados	25
5 MATERIAL E MÉTODOS.....	27
5.1 Caracterização da área do estudo.....	27
5.2 Dados climáticos.....	28
5.3 Amostragem do solo	29
5.4 Análises do solo em laboratório.....	30
5.5 Imagem Landsat-8	31
5.6 Escolha da imagem Landsat-8 para o estudo.....	32
5.7 Pré-processamento da imagem Landsat-8	33
5.8 Análise geoestatística multivariada.....	34
5.9 Aquisição dos dados	37
5.9.1 Modelagem Anamorfose Gaussiana.....	37
5.9.2 Modelo Linear de Correção Regionalização (MLC).....	38

5.9.3 Cokrigagem	39
5.9.4 Cokrigagem Fatorial (CKF)	39
5.9.5 Análise de componentes principais (método Varimax)	40
5.9.6 Cokrigagem em bloco	41
5.9.7 Cokrigagem Multi Colocada	42
5.9.8 Análise de componentes principais	42
5.9.9 Cokrigagem Multi-colocada fatorial	43
5.10 Validação cruzada	43
6 RESULTADOS E DISCUSSÃO	45
6.1 Delimitação das zonas de manejo (ZM _S) utilizando as variáveis de solo.....	45
6.1.1 Análise descritiva dos dados	45
6.1.2 Análise de correionalização	51
6.1.3 Validação cruzada das variáveis de solo pela geoestatística multivariada.....	57
6.1.4 Cokrigagem das variáveis do solo.....	70
6.1.5 Análise Regionalizada Fatorial	77
6.2 Delimitação das zonas de manejo (ZM _S) utilizando dados da radiância espectral do Landsat-8.....	80
6.2.1 Análise descritiva dos dados	80
6.2.2 Análise de correionalização	82
6.2.3 Validação cruzada para o modelo das variáveis espectrais.....	88
6.2.4 Análise Regionalizada Fatorial	96
6.3 Delimitação das Zonas de Manejo (ZM _S) pela fusão de dados de solo e de sensoramento remoto	102
6.3.1 Definição do conjunto de dados para o modelo fusionado	102
6.3.2 Análise descritiva dos dados	102
6.3.3 Análise de correionalização	105
6.3.4 Validação cruzada para o modelo fusionado.....	110
6.3.5 Cokrigagem Multicolocada para as variáveis fusionadas	119
6.3.6 Análise Regionalizada Fatorial	123
7 CONSIDERAÇÕES FINAIS	129
8 CONCLUSÕES	131
9 REFERÊNCIAS	133

LISTA DE FIGURAS

Figuras	Páginas
1. Projeção de expansão da área plantada de milho, soja e cana-de-açúcar entre 2008/09 a 2019/20	11
2. Classificação dos fatores de produção vegetal que afetam direta e indiretamente os processos fisiológicos das plantas	12
3. Bandas primárias de absorção e fatores responsáveis por mudanças na curva de reflectância espectral	16
4. Variograma teórico com ilustração dos seus parâmetros	20
5. Localização das áreas produtoras de cana-de-açúcar da Usina Açucareira São Manoel S.A. São Paulo.....	28
6. A precipitação total (mm) e temperatura (°C) média mensais registrados pela estação agrometeorológica de São Manuel –SP, para o ciclo da cana-de-açúcar 2013/2014.....	29
7. Locais das amostras de solo em uma malha regular de 100 m em campo de cana-de-açúcar.....	30
8. Fluxograma da parte A, análise geoestatística multivariada aplicada em variáveis de solo e dados de radiância espectral do Landsat-8.....	35
9. Fluxograma da segunda parte B que mostram os dados no processo de fusão.	36
10. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m.....	47
11. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m. (Continuação).....	48
12. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m.....	49
13. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar	53
14. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar (continuação)	54
15. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar	55
16. Validação cruzada para Ds	58

17. Validação cruzada para CTC	59
18. Validação cruzada para Ca	60
19. Validação cruzada para CE.....	61
20. Validação cruzada para CC	62
21. Validação cruzada para K.....	63
22. Validação cruzada para Mg	64
23. Validação cruzada para MO	65
24. Validação cruzada para P	66
25. Validação cruzada para S	67
26. Validação cruzada para argila.....	68
27. Validação cruzada para pH.....	69
28. Validação cruzada para silte	70
29. Interpolação por cokrigagem da Ds cultivado com cana-de-açúcar.....	71
30. Interpolação por cokrigagem da CTC do solo cultivado com cana-de-açúcar.....	71
31. Interpolação por cokrigagem do Ca no solo cultivado com cana-de-açúcar	72
32. Interpolação por cokrigagem do CE no solo cultivado com cana-de-açúcar	72
33. Interpolação por cokrigagem do CC no solo cultivado com cana-de-açúcar	73
34. Interpolação por cokrigagem do K no solo cultivado com cana-de-açúcar	73
35. Interpolação por cokrigagem do Mg no solo cultivado com cana-de-açúcar.....	74
36. Interpolação por cokrigagem do MO no solo cultivado com cana-de-açúcar.....	74
37. Interpolação por cokrigagem do P no solo cultivado com cana-de-açúcar	75
38. Interpolação por cokrigagem do S no solo cultivado com cana-de-açúcar	75
39. Interpolação por cokrigagem da argila no solo cultivado com cana-de-açúcar	76
40. Interpolação por cokrigagem do silte do solo cultivado com cana-de-açúcar.....	76
41. Interpolação por cokrigagem do pH no solo cultivado com cana-de-açúcar	77
42. Mapa em três zonas de manejo (ZMs) para o primeiro fator do modelo de solo	79
43. Mapa representado em três zonas de manejo (ZMs) para o segundo fator do modelo de solo.....	80
44. Variogramas diretos e cruzados das bandas espectrais e termais da imagem do Landsat-8.....	83
45. Variogramas diretos e cruzados das bandas espectrais e termais da imagem do Landsat-8 (continuação)	84

46. Variogramas diretos e cruzados das bandas espectrais e termiais da imagem do Landsat-8	85
47. Os resultados da validação cruzada para banda espectral 1 do Landsat-8	88
48. Os resultados da validação cruzada para banda espectral 2 do Landsat-8	89
49. Os resultados da validação cruzada para banda espectral 3 do Landsat-8	90
50. Os resultados da validação cruzada para banda espectral 4 do Landsat-8	91
51. Os resultados da validação cruzada para banda espectral 5 do Landsat-8	92
52. Os resultados da validação cruzada para banda espectral 6 do Landsat-8	93
53. Os resultados da validação cruzada para banda espectral 7 do Landsat-8.	94
54. Os resultados da validação cruzada para banda termal 10	95
55. Os resultados da validação cruzada para banda termal 11 do Landsat-8	96
56. Mapa em três zonas de manejo (ZMs), de acordo com o primeiro fator em curta escala (350 m), para o modelo espectral.	99
57. Mapa em três zonas de manejo (ZMs), de acordo com o primeiro fator em longa escala (750 m) para o modelo espectral.	101
58. Mapa em três zonas de manejo (ZMs), de acordo com o segundo fator em longa escala (750 m) para o modelo espectral.	101
59. Variogramas diretos e cruzados das variáveis do modelo de fusão	107
60. Variogramas diretos e cruzados das variáveis do modelo de fusão (Continuação)....	108
61. Variogramas diretos e cruzados das variáveis do modelo de fusão	109
62. Validação cruzada para Ds 0,2-0,4 m.....	110
63. Validação cruzada para CTC 0-0,2 m	111
64. Validação cruzada para CTC 0,2-0,4 m	112
65. Validação cruzada para argila 0-0,2 m	113
66. Validação cruzada para argila 0,2-0,4 m	114
67. Validação cruzada para CC 0-0,2 m.....	115
68. Validação cruzada para CC 0,2-0,4 m.....	116
69. Validação cruzada para MO 0-0,2 m.....	117
70. Validação cruzada para matéria orgânica 0,2-0,4 m	118
71. Mapa da Ds de 0,2-0,4 m interpolado pelo modelo de fusão	119
72. Mapa da CTC de 0-0,2 m interpolado pelo modelo de fusão.....	119
73. Mapa da CTC de 0,2-0,4 m interpolado pelo modelo de fusão.....	120
74. Mapa da argila de 0-0,2 m interpolado pelo modelo de fusão	120

75. Mapa da argila de 0,2-0,4 m interpolado pelo modelo de fusão	121
76. Mapa da CC de 0-0,2 m interpolado pelo modelo de fusão	121
77. Mapa da CC de 0,2-0,4 m interpolado pelo modelo de fusão	122
78. Mapa da MO de 0-0,2 m interpolado pelo modelo de fusão	122
79. Mapa da MO de 0,2-0,4 m interpolado pelo modelo de fusão	123
80. Mapa representado em três zonas de manejo (ZMs) para o primeiro fator em escala curta (250 m) para o modelo de fusão	127
81. Mapa em três zonas de manejo (ZMs) de acordo com o primeiro fator em escala longa (750 m) para o modelo de fusão.	128
82. Mapa em três zonas de manejo (ZMs) de acordo com o segundo fator em escala longa (750 m) para o modelo de fusão.	128

LISTA DE TABELAS

Tabelas	Páginas
1. Balanço final da safra 2012/2013 na região Centro-Sul comparado com o resultado da safra anterior.....	9
2. Estimativa da safra 2013/2014 na região Centro-Sul	10
3. Landsat 8 Operational Land Imager (OLI) e Thermal Infrared Sensor (TIRS)	32
4. Estádios fenológicos do crescimento da cana-de-açúcar.....	33
5. Estatística descritiva das propriedades físico-químicas do solo.....	46
6. Matriz de correlação das das propriedades físicas e químicas do solo na profundidade 0-0,2 m.....	50
7. Coeficiente estrutural de correlação das propriedades físicas e químicas do solo na profundidade 0-0,2 m na escala curta 380 m	56
8. Decomposição das variáveis Gauss do solo a partir dos fatores regionalizados; relataram os autovalores diferentes de zero e as percentagens da variância explicada para cada escala espacial.....	78
9. Estatística descritiva das bandas espectrais da imagem do Landsat-8	81
10. Matriz de correlação de Pearson para as bandas espectrais e termais da imagem do Landsat-8.....	81
11. Coeficientes estruturais na escala curta para as bandas espectrais e termais da imagem Landsat-8.....	87
12. Coeficientes estruturais na escala longa para as bandas espectrais e termais da imagem Landsat-8.....	87
13. Decomposição em fatores regionalizados das bandas gaussianas e também os autovalores diferentes de zero e as porcentagens da variância explicada para cada escala espacial.....	98
14. Estatística descritiva das variáveis do modelo fusionado.....	103
15. Matriz de correlação das variáveis do modelo de fusão	104
16. Fatores regionalizados em escala curta (250 m) fator correspondente ao valor próprio superior a um.....	125
16.Fatores regionalizados em escala curta (600 m) fator correspondente ao valor próprio superior a um.....	125

1 RESUMO

A cana-de-açúcar é uma cultura energética importante comercialmente devido a sua alta produtividade em biomassa e devido seu excelente equilíbrio de gases de efeito estufa e o uso eficiente dos recursos energéticos. Portanto, é necessário compreender os fatores relacionados à produtividade da cana-de-açúcar. Agricultura de Precisão (AP) apresenta-se como uma ferramenta para auxiliar o agricultor na determinação das melhores estratégias de gestão a ser adotado, a fim de aumentar a eficiência das atividades agrícolas. AP requer o apoio de tecnologias de informação espacial, para definir zonas específicas de manejo, acessando as variações do solo e das culturas no campo. AP é uma abordagem de sistema, onde podem ser aplicadas técnicas de fusão de dados para ajudar os agricultores no manejo da cultura. A abordagem de fusão de dados permite a delimitação das Zonas de Manejo (ZMs) em mapas estimados em alta resolução que podem ser utilizados para prescrever o manejo em taxas variáveis de aplicação. Portanto, através da fusão dos parâmetros de solo com dados espectrais de sensoriamento remoto, por meio de técnicas de geoestatística multivariada, foi possível obter estimativas confiáveis das propriedades do solo em diferentes escalas espaciais, aumentando a eficácia do manejo em locais específicos na cultura da cana-de-açúcar. A análise geoestatística multivariada foi dividida em duas partes: Primeira parte destinou-se a delimitação de duas zonas homogêneas de manejo

atraves das variáveis químicas e físicas do solo e dados de radiância espectral do Landsat-8. A segunda parte objetivou mostrar o potencial da fusão entre os dados do solo e os dados espectrais do Landsat-8, delimitando as zonas homogêneas de manejo. Três Modelos Lineares de Corregionalização (MLC) foram desenvolvidos: o primeiro para as variáveis de solo, o segundo para os dados espectrais e o terceiro para a fusão de dados solo e bandas espectrais. O conjunto de dados espacial multivariado foi analisado por: cokrigagem e cokrigagem multicolocada para produzir os mapas temáticos das variáveis em estudo. Cokrigagem Fatorial (CKF) e Cokrigagem Multicolocada Fatorial (CKMF) foram utilizadas para determinar fatores regionalizados em escala dependente. As ZMs utilizando apenas variáveis do solo caracterizaram a zona central diferenciada em comparação ao manejo das demais áreas periféricas, porque apresentaram uma textura mais fina e mais rica em macronutrientes. As ZMs definidas pelos dados espectrais do Landsat-8 caracterizaram zonas homogêneas em conteúdo de água na cultura pelas bandas do azul e das bandas 6 e 7 e temperatura da superfície pelas bandas termais 10 e 11. Houve o aumento em capacidade de continuidade e previsão espacial que não seria possível usando somente as esparsas observações de solo. Uma das constatações significativas foi em relação aos mapas cokrigados das propriedades do solo, a partir do modelo de fusão, com um aumento da variabilidade devido à introdução das variáveis espectrais em escala fina. A abordagem de fusão de dados de solo e de sensoriamento remoto demonstrou que houve redução da escala para estimativas das variáveis de solo, utilizando variáveis secundárias de maior resolução, neste caso os dados de reflectância do Landsat-8. Os três modelos utilizados foram eficientes na definição das ZMs, para a melhor tomada de decisão no planejamento da cultura.

Palavras-chave: Agricultura de Precisão, Cokrigagem Fatorial, *Saccharum spp.*

MULTIVARIATE GEOSTATISTICS FOR DELINEATING MANAGEMENT ZONES IN A SUGARCANE. Botucatu, 2014. 143p. Tese (Doutorado em Agronomia/Irrigação e Drenagem) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista.

Author: ANDERSON ANTONIO DA CONCEIÇÃO SARTORI

Adviser: CÉLIA REGINA LOPES ZIMBACK

Co-advisor: ROBERTO LYRA VILLAS BÔAS

2 SUMMARY

The sugarcane is one of the commercially important energy crop due to its high productivity and biomass due to its excellent balance of greenhouse gas emissions and efficient use of energy resources. Therefore, it is necessary to understand factors related to productivity of sugar cane. Precision Agriculture (PA) is presented as a tool to assist farmers in determining best management strategies to be adopted in order to increase the agricultural activities efficiency. PA requires spatial information technologies support, to define specific areas of site management, accessing soil and crops variations in the field. PA is an approach, where data fusion techniques can be applied to help farmers in crop management. The integration process lead to the delineation of management estimates and zone maps in high resolution which can be used to prescribe management in variables application rates. Therefore, by merging the soil parameters with spectral remote sensing data, using geostatistics multivariate, it was possible to obtain reliable estimates of soil properties at different spatial scales, increasing the effectiveness of management in specific locations in sugarcane cultivation. The complex geostatistical multivariate analysis was divided into two parts: First part was aimed at delineation of two homogeneous management zones through physical and chemical characteristics of the soil and spectral radiance data from the Landsat-8. And second part aimed at showing the potential of fusion between soil data and spectral data from Landsat-8 to improve the delineation of homogeneous management. Three Linear Models Coregionalization (LMC) have been developed: one for soil variables, the second for the spectral data and the third for the fusion of soil data and spectral bands. The spatial data set was analyzed by multivariate: cokriging and multicollocated cokriging to produce study variables thematic maps.

Factorial and Multicollated Cokriging had been used to determine factors regionalized dependent on scale. MZs using only the characteristics of the soil, characterized the central area different compared to the handling of other more peripheral areas, because it has a finer texture and richer macronutrients. MZs defined by the spectral data Landsat-8 characterized homogeneous zones water contenting the culture by bands of blue and bands 6 and 7 and the surface temperature of the thermal bands 10 and 11. There has been increased the capacity of continuity and spatial prediction which would not be possible using only the sparse soil observations. One of the results was significant in relation to soil cokriging properties maps from the fusion model, with greater variability due to the introduction of the spectral fine-scale variables. The soil fusion approach data and remote sensing has shown that a reduction of the soil scale estimates variables using secondary variables of higher resolution, in this case the reflectance data from the Landsat-8. The three models used have been effective in defining MZs for better decision making in planning culture.

Keywords: Precision Agriculture, Factorial Cokriging, *Saccharum spp.*

3 INTRODUÇÃO

A área de cultivo de cana-de-açúcar (*Saccharum spp.*) continua em expansão no Brasil. O maior aumento em área encontra-se em São Paulo, Mato Grosso do Sul, Goiás e Paraná, ou seja, os estados com as maiores áreas de crescimento, com 144.300 ha, 57.900 ha, 59.900 ha e 58.300 ha, respectivamente (CONAB, 2014).

O rendimento médio nacional está estimado em 73,569 kg.ha⁻¹ e as médias da região Centro-Sul são as maiores, devido às condições de produção, tamanho de lavoura, tipo de solo, topografia, clima e tecnologia aplicada. A previsão total de cana a ser processada na safra 2014/2015 é de 671,69 milhões de toneladas, um aumento de 2,0% em relação à safra 2013/2014 e aumento de 12,87 milhões de toneladas em relação à safra 2012/2013 (CONAB, 2014).

A produção de açúcar para a safra 2014/15 está estimada em 39,46 milhões de toneladas, 4,17% a mais que as 37.880.000 toneladas da última safra. A produção total de etanol esperada para a safra 2014/2015 é estimada em 28,37 bilhões de litros, com um aumento de 412.190.000 litros, ou 1,47% em comparação com os 27,96 bilhões de litros da safra 2013/2014 (CONAB, 2014).

A cana-de-açúcar é uma cultura energética 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. Mais recentemente, abordagens em cogeração de energia, aumentaram o valor de bioetanol, bem como a quantidade de eletricidade que pode ser gerada pela queima dos resíduos fibrosos (bagaço). Dezenas de produtos de base biológica têm sido derivadas da cana-de-açúcar, que varia desde bio fertilizantes a bio plásticos. A cana-de-açúcar reina entre as culturas de bioenergéticas de primeira geração, devido seu excelente equilíbrio de gases de efeito estufa e o uso eficiente dos recursos energéticos.

Esses dados relevantes mostram que a cultura é uma das principais atividades agrícolas do país, pois a produtividade agrícola é essencial para os setores de açúcar e álcool. O setor bioenergético, como é chamado atualmente, é o segmento do agronegócio que tem apresentado maior crescimento em comparação a outros setores da agricultura.

Como a cultura é de grande importância da produtividade para a economia brasileira, é necessário compreender os fatores relacionados à produtividade da cana-de-açúcar. A produção é geralmente influenciada pelas propriedades do solo, clima, uso de insumos externos, pragas e doenças, cultivares e variedades, mecanização, sistema de colheita, etc. A necessidade de incorporar novas tecnologias é essencial para a racionalização de todo o processo de produção, uma vez que esta implica em redução de custos operacionais e aumento de rentabilidade em qualquer atividade do agronegócio.

A Agricultura de Precisão (AP) apresenta-se como uma ferramenta para auxiliar o agricultor na determinação das melhores estratégias de gestão a serem adotadas, a fim de aumentar a eficiência das atividades agrícolas. AP permite que os agricultores entendam melhor os processos de controle de produção seguida do gerenciamento do sistema de cultivo com busca de melhores rendimentos. AP é um sistema integrado que, envolvendo técnicas de gestão (plantio, aplicação de pesticidas, colheita e outros), que podem ser planejadas e integradas em programas computacionais, a fim de definir práticas rentáveis e sustentáveis.

AP requer o apoio de tecnologias de informação espacial, para definir zonas específicas de manejo, acessando as variações do solo e das culturas no campo. As zonas de manejo (ZMs) são definidas como regiões de subcampos, dentro dos quais os diferentes fatores agem sobre a cultura (ou seja, as diferenças sazonais de clima, solo, práticas agrícolas, etc) deverão ser uniforme.

Para aplicação das ZMs é necessário discriminar a variabilidade espacial das práticas utilizadas no manejo da cultura. A variabilidade espacial e temporal das propriedades do solo que podem influenciar o crescimento, produtividade e teor de sacarose da cana, a uma escala dentro de campo.

No entanto, a relevância da AP no manejo sustentável dos recursos terrestres não tem focado estudos sobre a integração das propriedades das plantas e do solo na definição de zonas de manejo na cultura da cana-de-açúcar no Brasil. Os estudos que vêm sendo realizados tiveram como objetivo definir zonas de manejo, utilizando apenas abordagem univariada.

Devido à complexidade das interações entre os fatores que afetam o cultivo da cana-de-açúcar, torna-se crítico a determinação da quantidade e qualidade da produtividade, então justifica a abordagem multivariada na determinação de zonas de manejo no campo. Há um número crescente de trabalhos científicos que utilizam abordagem multivariada no delineamento de ZM em diversas culturas, como exemplo, uva (MORARI et al., 2009), trigo duro (CASA; CASTRIGNANÒ, 2008; DIACONO et al., 2013), milho (LÓPEZ-LOZANO et al., 2010) ou maçã (AGGELOPOOULOU et al., 2013). No entanto, não foram encontradas referências sobre a abordagem multivariada para a determinação de zonas específicas de manejo na cultura da cana-de-açúcar.

Para produzir uma avaliação precisa para a aplicação da AP é necessário coletar uma grande quantidade de dados de solo e de planta, porém estes dados são de alto custo e de análises laboratoriais demoradas. Portanto, com a fusão dos parâmetros de solo com dados espectrais de sensoriamento remoto e a utilização de geoestatística multivariada, é possível obter estimativas mais confiáveis das propriedades do solo em diferentes escalas espaciais, aumentando a eficácia do manejo localizado na cultura da cana-de-açúcar.

O objetivo deste estudo foi delinear zonas homogêneas de manejo em uma área cultivada com cana-de-açúcar na região central do estado de São Paulo-Brasil. Para alcançar esse objetivo, foi aplicada abordagem geoestatística multivariada, utilizando variáveis de solo e bandas espectrais do satélite Landsat-8, para sintetizar a estrutura espacial conjunta das variáveis. Tendo como hipótese que o uso de dados espectrais em combinação com os atributos do solo propicia o reconhecimento e melhor avaliação da variabilidade espacial dentro do campo, permitindo o manejo sustentável da cultura.

4 REVISÃO DE LITERATURA

4.1 A cultura da cana-de-açúcar e sua importância para o agronegócio brasileiro

O Brasil apresenta condições climáticas e geográficas privilegiadas para as práticas agrícolas. Devido a esse fato, a agricultura sempre foi importante para a economia. 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.

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), na primeira década do século XXI a área plantada com culturas agrícolas monitoradas pelo Levantamento Sistemático de Produção Agrícola (LSPA) do país aumentou cerca de 30%, chegando a 64 milhões de hectares (IBGE, 2010).

A pressão por fontes de energia mais limpas que aquelas oriundas dos combustíveis fósseis - responsáveis por 89% da matriz energética global (FAO, 2005) trouxe destaque para os biocombustíveis, entre eles o etanol da cana-de-açúcar, inaugurando uma nova fase para o setor sucroalcooleiro. O país é o maior produtor e exportador de açúcar e etanol de cana-de-açúcar e o maior produtor mundial de cana-de-açúcar, com a região Centro-Sul como principal produtora (HISSA, 2011).

De acordo com o levantamento realizado pela ÚNICA (2013), a região Centro-Sul teve um aumento de 16,93% na produção de etanol (1,264 milhões de litros) e um aumento de 8,92% de açúcar (2,793 mil toneladas), entre as safras 2011/2012 e 2012/2013 como mostra (Tabela 1), tendo como principal objetivo atender à demanda nacional gerada pela inserção de automóveis bicombustíveis no mercado, e à internacional gerada pelo acréscimo nos preços do açúcar.

Tabela 1. Balanço final da safra 2012/2013 na região Centro-Sul comparado com o resultado da safra anterior

Produtos	Safr		Var. (%)
	2011/2012	2012/2013	
Cana-de-açúcar ¹	493,149	532,758	8,03%
Açúcar ¹	31,304	34,097	8,92%
Etanol anidro ²	7,466	8,730	16,93%
Etanol hidratado ²	13,076	12,632	-3,40%
Etanol total ²	20,542	21,362	3,99%
ATR ¹	67,830	72,228	6,48%
ATR/tonelada de cana ³	137,54	135,57	-1,43%
Mix (%) açúcar	48,44%	49,54%	-
etanol	51,56%	50,46%	-
Litros etanol/tonelada de cana	41,65	40,10	-3,74%
kg açúcar/tonelada de cana	63,48	64,00	0,83%

Fonte: UNICA. Nota: ¹ - mil toneladas; ² - milhões de litros; ³ - kg de ATR/ tonelada de cana.

As estimativas para safra 2013/2014, reforçando o otimismo do setor originado pelas melhores condições climáticas e pela renovação do canavial para esta safra está ilustrado na Tabela 2.

Tabela 2. Estimativa da safra 2013/2014 na região Centro-Sul

Produtos	Safra		Var. (%)
	2012/2013	2013/2014	
Cana-de-açúcar ¹	532,758	589,600	10,67%
Açúcar ¹	34,097	35,500	4,11%
Etanol anidro ²	8,730	11,200	28,29%
Etanol hidratado ²	12,632	14,171	12,18%
Etanol total ²	21,362	25,371	18,77%
ATR ¹	72,228	80,600	11,59%
ATR/tonelada de cana ³	135,57	136,70	0,83%
Mix (%) açúcar	49,54%	46,22%	-
etanol	50,46%	53,78%	-
Açúcar disponível para exportação ¹	24,312	25,800	-6,12%
Exportação de etanol ²	3,458*	2,700	-21,92%

Fonte: UNICA. Nota: ¹ - mil toneladas; ² - milhões de litros; ³ - kg de ATR/ tonelada de cana; * volume de etanol que saiu das unidades produtoras do Centro-Sul com destino ao mercado externo no período de abril/2012 a março/2013.

No Brasil, onde há longa tradição no cultivo da cana-de-açúcar, a produção do etanol vem sendo competitiva em relação a outros países, como os Estados Unidos. Além disso, a cana-de-açúcar é o terceiro cultivo mais representativo em área do país, atrás apenas da soja e do milho. Para atender às crescentes demandas do mercado externo e interno, por etanol e açúcar (entre outros subprodutos da cana), as previsões são de expansão de área plantada, que deve ultrapassar 12,9 milhões de hectares até 2020 (AgraFNP, 2010; MAPA, 2010) e de intensificação da produtividade do cultivo, como mostra a Figura 1.

Como resultado, a agroindústria sucroalcooleira brasileira possui alto valor socioeconômico, sendo estratégica pela importância do álcool na matriz energética do país, que apresenta a frota de veículos menos dependente de petróleo do mundo. As perspectivas são de continuidade de expansão do setor, o que implica em ampliação de áreas de cultivo e aumento da produtividade (GODOY, 2007).




Figura 1. Projeção de expansão da área plantada de milho, soja e cana-de-açúcar entre 2008/09 a 2019/20.

Fonte: Ministério da Agricultura Pecuária e Abastecimento.

Com a crescente perspectiva do cultivo de cana-de-açúcar, a compreensão dos fatores associados à sua produção, seleção de áreas potenciais para o cultivo, comportamento da produtividade, etc. tornou-se importante.

4.2 Influência das variáveis ambientais e edáficas na produção da cana-de-açúcar

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 requer 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. As melhores condições para a cultura ocorrem nos períodos 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).

Marchiori (2004) considerou a temperatura, a insolação e a umidade como variáveis climáticas determinantes para o desenvolvimento da cana-de-açúcar. Citando vários outros autores, elegeu o clima como o fator que mais influência na produtividade da cultura. Além do clima, estudou as interações com outras variáveis que influenciam direta e indiretamente a produção da planta (Figura 2).




Figura 2. Classificação dos fatores de produção vegetal que afetam direta e indiretamente os processos fisiológicos das plantas.

Linhas cheias correspondem a uma ação mais efetiva do que as linhas interrompidas.

Fonte: Castro, 1999 citado por Marchiori (2004).

Segato et al. (2006) relacionaram variáveis ambientais, de manejo e genéticas às fases do ciclo fenológico da cana-de-açúcar. Considerando somente as variáveis ambientais, a brotação e o enraizamento são influenciados por: temperatura, umidade relativa do ar, doenças, pragas, plantas daninhas, textura e estrutura do solo. O perfilhamento é influenciado pelas variáveis: radiação solar, temperatura, umidade, aeração, vento, doenças, pragas e plantas daninhas. E a maturação é influenciada pelas variáveis: temperatura, umidade, vento, pragas, doenças e características do solo.

O conhecimento da capacidade produtiva dos solos é um dos principais fatores de sucesso do empreendimento agrícola. Portanto, o conhecimento das características inerentes a cada solo, os chamados fatores edáficos, é importante para julgar o seu potencial de produção agrícola (LEPSCH, 1987).

Entre os diferentes parâmetros que descrevem a variabilidade na paisagem, topografia e solo são fatores-chave que controlam a variabilidade das culturas (ROBERT, 1993). As variações no crescimento vegetativo das culturas são afetadas por diferenças de microambientes e práticas de manejo.

Além disso, a variabilidade espacial e temporal das propriedades do solo pode afetar o crescimento da cana, produção e qualidade de sacarose a uma escala dentro do campo. A magnitude e a estrutura desta variabilidade dentro do campo pode

sugerir a adequação do manejo localizado (GODWIN; MILLER, 2003; MZUKU et al., 2005). Mas é importante não só avaliar a variação espacial de atributos do solo, mas também identificar as fontes de variação. Se as atividades do homem são as causa de deficiências ou excessos de algum elemento, os agricultores devem modificar seu manejo agrícola; se as concentrações derivam de material de origem ou do tipo de solo, qualquer tentativa nesse sentido seria inútil e outros tipos de soluções seriam necessários.

Variabilidade do solo é o resultado de ambos os processos, naturais e práticas de manejo, atuando em diferentes escalas espaciais e temporais. Variabilidade natural resulta dos processos geológicos e pedológicos que são complexos. Fatores formadores do solo, tais como materiais de origem, biota, clima e topografia, explicam a maior variabilidade; no entanto, as práticas de manejo também podem afetar de forma significativa variabilidade do solo. Alguns dos possíveis fatores que governam as variações de solo são susceptíveis de ter uma ação de curto alcance, enquanto outras operam a distâncias mais longas. Como consequência, as variáveis do solo devem estar correlacionadas de tal forma que é dependente da escala (CASTRIGNANÒ et al., 2000).

Variações climáticas associadas com todos os fatores edáficos estão inter-relacionadas, direta e indiretamente influenciando o calendário das culturas. Se houver variabilidade climática, há necessidade de mais pesquisas sobre o assunto, a fim de ajustar as colheitas no tempo e no espaço para atingir alto rendimento.

4.3 Sensoriamento Remoto na cultura da cana-de-açúcar

Sensoriamento remoto em geral refere-se à medição de energia eletromagnética emitida ou refletida pela superfície da Terra usando uma câmera ou sensor. A aplicação desta tecnologia para a agricultura faz uso de uma ampla gama de instrumentos, a partir de câmeras suspensas no ar por sensores montados em satélites em órbita. A abordagem fornece informações agronômicas valiosas sobre manejo do solo, salinidade e estado dos nutrientes na planta. O desenvolvimento de métodos de sensoriamento remoto levou a melhor compreensão de como as mudanças de reflectância da folha ocorrem 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 aperfeiçoar a gestão agrícola como adubação, irrigação ou outras operações agrotécnicas (FRANZEN et al., 2002; DE BENEDETTO et al., 2013; YAN et al., 2007). 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; YANG et al., 1997; 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 subáreas onde se espera que os efeitos sobre a cultura das diferenças sazonais de clima, solo, manejo etc, sejam uniforme (LARK, 1998).

Para produzir uma avaliação precisa e custo eficaz em termos de variação espacial, na escala exigida pela agricultura de precisão, há uma demanda crescente para a aquisição rápida, relativamente barata e não invasiva de informações do solo e planta em escala precisa. Os altos custos para amostragem tradicional do solo e análises laboratoriais de plantas sugerem a necessidade de dados espectrais que podem detectar condições irregulares e fornecem evidências de que uma anomalia está presente em cada local do campo (ADAMCHUK, 2011).

Um grande número de pesquisas que abrange quase quatro décadas, tem demonstrado que grande parte dessas informações necessárias está disponível remotamente, através veículos aéreos não tripulados (VANT) e satélites baseados em sistemas de sensores. Tecnologia de sensoriamento remoto quando combinada com notáveis avanços do Sistema de Posicionamento Global (GNSS), sistemas de informação geográfica (SIG), monitores de produtividade e avançados modelos de simulação tem o potencial de transformar as formas que os produtores de cana-de-açúcar gerenciam áreas extensas e permitem implementar técnicas de agricultura de precisão com menor custo relativo.

4.3.1 Propriedades de reflectância espectral no manejo das culturas

Características espectrais da vegetação têm características muito importantes: dois vales na porção espectral do visível são determinados pelos pigmentos contidos na planta. A clorofila absorve fortemente na região do vermelho (680 nm) e azul (510 nm), também conhecido como as bandas de absorção de clorofila (THENKABAIL et al., 2012). A assinatura de reflectância tem um aumento drástico na reflexão para a vegetação saudável em torno de 700 nm. No infravermelho próximo (NIR), entre 700 e 1300 nm, uma folha da planta tipicamente normalmente refletirá entre 40% e 60%, o resto é transmitido, com apenas 5% sendo adsorvida.

Dados de sensoriamento remoto é uma função de domínio óptico reflexivo, fonte de custo único e eficaz, qual fornece informações espacial e temporal sobre parâmetros biofísicos e bioquímicos da vegetação distribuída na superfície da terra (HOUBORG et al., 2011). A quantidade de folhas verdes da planta é uma variável chave usada pelos fisiologistas e modeladores de culturas para estimar cobertura vegetal, bem como o crescimento da cultura e previsão da produtividade. Estas folhas desempenham um papel importante em vários processos biofísicos tais como a transpiração das plantas e as trocas de CO₂ (THENKABAIL et al., 2012). Devido às folhas verdes das plantas estarem funcionalmente ligadas à reflectância do dossel, a sua obtenção a partir de dados de sensoriamento remoto levou muitas investigações e estudos ao longo dos anos (APARICIO et al., 2000; GITELSON, 2004; HABOUDANE et al., 2004; HOUBORG et al., 2009).

As folhas verdes da planta normalmente exibem baixa reflectância e transmitância em regiões do espectro visível (ou seja, 400 a 700 nm) devido à forte absorvância por pigmentos de plantas fotossintéticas (CHAPPELLE et al., 1992). Por outro lado, reflectância e transmitância são ambos geralmente elevados nas regiões do infravermelho próximo (NIR, 700-1300 nm), porque há pouca absorvância por partículas subcelulares ou pigmentos e também porque não há dispersão considerável nas interfaces da parede celular do mesófilo foliar (GAUSMAN, 1974; GAUSMAN, 1976; SLATON et al., 2001). Esta divergência acentuada das propriedades de reflectância, entre comprimentos de onda no visível e NIR, sustenta a maioria das abordagens remotas para monitoramento e manejo de culturas e comunidades naturais de vegetação (BAUER, 1975; KNIPLING, 1970).

As principais bandas de absorção são as responsáveis por mudanças na curva espectral de reflectância (Figura 3). Este comportamento espectral é útil para avaliar o vigor da planta e para separar dossel do solo nu. Além disso, a discriminação das classes de vegetação possibilita a discriminação da reflectância do NIR devido às diferenças entre as espécies de plantas. O comportamento das mudanças espectrais nas folhas durante a senescência e em plantas submetidas ao estresse (por exemplo, doenças, pragas, escassez de N) reflete mais luz vermelha e absorve mais NIR. Comportamento oposto é mostrado em plantas saudáveis, com altos valores de reflectância na região do NIR e valores baixos na faixa do vermelho (GAUSMAN et al., 1976; GAUSMAN, 1981; PINTER et al., 2003). O solo tem baixa reflectância no azul e as suas propriedades de reflectância aumentam monotonicamente nas regiões espectrais do visível e NIR (PRICE, 1990).




Figura 3. Bandas primárias de absorção e fatores responsáveis por mudanças na curva de reflectância espectral.

Fonte: Ponzoni e Shimabukuro, 2007.

Outros fatores relacionados ao comportamento espectral são a composição das espécies, estágio de desenvolvimento, condições de repouso, sazonalidade

e as práticas de manejo utilizadas (JONCKHEERE et al., 2004). As mudanças fenológicas e condições ambientais afetam as etapas das propriedades biofísicas durante o desenvolvimento da vegetação.

Três fortes bandas de absorção de água são observadas em torno de 1400, 1900 e 2600 nm e podem ser usadas para estimar o teor de água da planta. No entanto, existem poucos estudos que investigaram o potencial de multi-colinearidade no conjunto de dados espectrais para estimar o teor de água da vegetação (MIRZAIE et al., 2014).

Conteúdo de água da folha é um indicador chave da saúde da planta, vigor e eficiência fotossintética (HARRY, 2006). O status da água na cultura é uma propriedade biofísica chave que é usada para manejar a irrigação, bem como para avaliar a saúde da cultura. Na maioria dos casos, está diretamente associado com a disponibilidade de água no solo e, quando este não é o caso (ou seja, disponibilidade de água não é o fator limitante), o status da água torna-se um indicador de saúde das culturas (THENKABAIL et al., 2012) .

O uso de imagem de satélite é uma alternativa eficaz da amostragem em campo para recuperação do conteúdo de água na folha, sendo não destrutivo e fornecendo cobertura espacial contínua de grandes áreas (SEPULCRE-CANTÓ et al., 2006).

O status hídrico da folha foi estimado com sucesso usando ondas curtas do infravermelho (CECCATO et al., 2001; ZYGIELBAUM et al., 2009). As moléculas de água na folha absorvem a energia eletromagnética ao longo das ondas curtas no infravermelho de 1300-2500 nm, onde existe uma forte absorção à 1450 nm, 1900 nm e 2100 nm e baixa absorção em 750 nm e 1200 nm (DATT, 1999).

Métodos de detecção na região do infravermelho termal (TIR) têm sido relatados como capazes de prever potencial de água nas folhas e caule, detectando a temperatura da folha (MOLLER et al., 2007).

Outra medida alternativa para o estresse das culturas pode ser derivada de imagens térmicas quantificando a temperatura das folhas, o que deve estar relacionado com a condutância foliar (MOLLER et al., 2007). Jones et al. (2002) sugeriram que esta medida poderia ser apropriada para culturas com dossel uniforme. Imagem termal em conjunto com o visível e NIR permite a exclusão de material não foliar

na estimativa da temperatura do dossel e a possibilidade de selecionar partes específicas do dossel para a estimativa do estresse hídrico (LEINONEN; JONES, 2004) .

Apesar das recentes melhorias significativas nos equipamentos computacionais e programas usados em imagens térmicas, há falta de conhecimento na ligação entre temperatura medida no dossel remotamente e medidas terrestres de estresse hídrico na cultura, como a condutância foliar e potencial de água na folha ou haste. No entanto, o conhecimento destas relações é necessário, a fim de traduzir os dados de imagens térmicas com precisão para as estimativas de déficit hídrico, que podem servir como ferramentas de apoio à decisão de irrigação (MOLLER et al., 2007).

4.4 Análise geoestatística dos dados

Solo e suas propriedades variam no espaço e no tempo, com grande complexidade, portanto, qualquer amostragem em um número finito de locais, inevitavelmente, daria uma descrição incompleta da variação natural. O reconhecimento da variabilidade espacial tem levado ao estudo da heterogeneidade do solo, que vão desde escala global a microescalas. Variabilidade do solo é o produto de muitos fatores interagindo que operam em diferentes escalas espaciais e temporais. As técnicas de medição dificilmente trabalham na mesma escala como o processo de interesse. Portanto, alguma variabilidade em pequena escala pode ser perdida porque há necessidade de amostragem em resolução menor e raramente pode ser alcançada (DE BENEDETTO, 2014; SIMOS; COSTANTINO, 2004).

Os recentes desenvolvimentos na teoria estatística nos permitem quantificar as relações espaciais entre os valores de amostragem e usar essas informações para a interpolação e mapeamento (HENGL et al., 2004). Estes avanços são baseados na teoria das variáveis regionalizadas (GOOVAERTS, 1997; JOURNAL; HUIJBREGTS, 1978).

O termo geoestatística refere-se à análise estatística dos fenômenos que variam de uma forma espacial contínua. Pode ser definida como as ferramentas que estudam e preveem a estrutura espacial de variáveis georreferenciadas. Geoestatística foi amplamente aplicada em ciência do solo para resolver o problema de estimativas das propriedades do solo em locais não visitados a partir de dados amostrais (WEBSTER;

OLIVER, 2001). Para uma apresentação detalhada da teoria da geoestatística, os conceitos estão expostos em Chilès e Delfiner (1999), Wackernagel (2003), entre outros.

Uma série de técnicas genéricas e robustas de interpolação espacial têm sido propostas (MITAS; MITOSA, 1999) e geoestatística (JOURNAL; HUIJBREGTS, 1978; MATHERON, 1971) tem sido geralmente preferido, porque nos permite levar em conta a correlação espacial entre as observações vizinhas, a fim de prever valores de atributos em locais não amostrados. As técnicas de interpolação disponíveis variam de algoritmos muito simples a procedimentos matemáticos avançados.

Krigagem (JOURNAL; HUIJBREGTS, 1978) é aceita por muitos cientistas do solo como uma técnica apropriada para estimar os valores das propriedades do solo em locais não amostrados ou sobre grandes glebas de terra. Em algumas situações, as informações são multivariadas: as amostras são coletadas em diversos locais e para cada um deles são realizadas várias medições. As ferramentas utilizadas na análise geoestatística multivariada são análogas à univariada e incluem a hipótese intrínseca, a covariância e cokrigagem (DE BENEDETTO, 2014). Usando essas relações em interpolação pode diminuir as incertezas de predição (GOOVAERTS, 1997).

4.4.1 Abordagem univariada

Na análise de dados, em primeiro lugar, a dependência espacial entre as observações devem ser caracterizadas. Geoestatística admite que as propriedades do solo são variáveis contínuas e apresentam modelos com função aleatória ou um processo aleatório (WEBSTER; OLIVER, 2001). Para fazer inferência sobre a função aleatória são necessários pressupostos de estacionariedade, entre os quais os mais utilizados são os relacionados com a hipótese intrínseca (MATHERON, 1973).

Hipótese intrínseca assume estacionariedade de primeira ordem dos momentos de incrementos lineares $[Z(x) - Z(x + h)]$ da função aleatória, onde x é o vetor de localização e h é o vetor de separação entre locais de amostragem chamado *lag*. Isto implica que os valores esperados de incrementos $[Z(x) - Z(x + h)]$ é igual a zero e a sua variância existe finita e é independente de posição x , mas depende exclusivamente de h . Estas duas condições estão expressas, nas Equações 1 e 2:

$$E[Z(x) - Z(x + h)] \quad (1)$$

$$VAR[Z(x) - Z(x + h)] = E[Z(x) - Z(x + h)]^2 = 2\gamma(h) \quad (2)$$

onde:

E indica os valores esperados e $\gamma(h)$ é a variância. A variância entre quaisquer dois locais pode ser estimada como sendo os quadrados médios das diferenças entre todas as observações separadas pelo mesmo intervalo de classe de distância (*lag*), na Equação 3:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i + h) - Z(x_i)]^2 \quad (3)$$

onde:

$Z(x)$ representa a variável medida no local alvo x e $N(h)$ corresponde ao número de pares de pontos separados por uma distância h .

A variância $\gamma(h)$ descreve como a variabilidade espacial entre os valores dos dados aumenta com a distância entre os dados. Na prática, a variância para uma dada direção é geralmente exibida em uma função teórica ajustada denominada variograma (Figura 4).




Figura 4. Variograma teórico com ilustração dos seus parâmetros.

Variogramas teóricos são caracterizados por três parâmetros que descrevem o espaço ao longo da área de estudo: patamar, alcance e efeito pepita (Figura 4). A variância aumenta com a distância e deve ser estabilizada a um valor constante (patamar) a uma dada distância de separação, o chamado intervalo de dependência espacial (alcance). O patamar aproxima da variância das amostras σ^2 para dados estacionários (ISAAKS; SRIVASTAVA, 1989).

As amostras separadas por distâncias superiores ao alcance não são espacialmente relacionados, porque a variância é igual a σ^2 , o que implica uma variação aleatória e sem correlação espacial. Se o variograma atinge um patamar à uma distância, a variável é estacionária. Se a variância aumenta continuamente, sem chegar a um patamar, indica a presença de efeitos de tendência e não-estacionariedade. Idealmente, o variograma experimental deve passar através da origem e então a variação é zero. No entanto, muitas propriedades do solo têm variância diferente de zero quando h tende a zero. Esta descontinuidade na origem é denominada efeito pepita e é representada por uma variação espacial inexplicável (microvariabilidade a uma distância menor do que a menor distância de amostragem) ou variância puramente aleatória (como medição ou erro de amostragem) (DE BENEDETTO, 2014).

Muitos, mas não todos, modelos matemáticos podem ser utilizados para descrever a variância dos dados espacial (modelos autorizados). As funções matemáticas mais utilizadas são; esférica, exponencial e gaussiana. Os variogramas às vezes mostram descontinuidade na forma e são necessárias funções mais complexas para descrevê-los. Uma maneira de fazer isso é através da combinação linear de duas ou mais funções, não necessariamente de mesma espécie e caracterizadas pela escala diferente, gerando um modelo aninhado. Modelos aninhados são comumente usado para descrever padrões agindo sobre múltiplas escalas espaciais (DE BENEDETTO, 2014).

Na análise variográfica, é importante verificar a presença de anisotropia. As propriedades do solo isotrópicas mostram o mesmo comportamento em todas as direções; neste caso todos os variogramas calculados para diferentes direções mostram aproximadamente a mesmo alcance e patamar e o variograma pode ser assumido, dependendo apenas da distância entre as amostras. Por outro lado, se os variogramas atingirem o mesmo patamar em diferentes alcances, o modelo apresenta anisotropia geométrica. Anisotropia zonal é quando os modelos apresentam patamares distintos

variando com as diferentes direções. Ele descreve um fenômeno em que diferentes populações estatísticas ocorrem na área de estudo. A vantagem da modelagem anisotrópica reside na sua capacidade de revelar e prever as mudanças importantes na dependência espacial em diferentes direções, que está relacionada em função dos processos de formação do solo (JOURNEL; HUIJBREGTS, 1978; McBRATNEY; WEBSTER, 1981).

A escolha do modelo do variograma é muito importante, porque cada tipo origina valores muito diferentes para efeito pepita e alcance, ambos são parâmetros críticos para a interpolação. A escolha e as estimativas do modelo são baseadas em critérios estatísticos de otimização, tais como minimização da soma das diferenças de quadrado entre os valores experimentais e modelo do variograma (DE BENEDETTO, 2014).

4.5 Abordagem multivariada

Ao longo da história da agricultura, os agricultores vêm tentando dividir a paisagem em áreas que possam ser gerenciadas com eficiência, para criar campos adequados para máquinas de grande porte. Em tempos mais recentes perceberam que muitas vezes as terras podem ser gerenciadas de forma melhor, dividindo seus campos em áreas menores denominadas "zonas de manejo" de acordo com a fertilidade natural do solo ou o desempenho real das culturas ao longo de vários anos (MILNE et al., 2012). Os gestores podem então ajustar a quantidade de fertilizante ou outros produtos químicos agrícolas aplicados a cada zona de manejo de acordo com o potencial da região para produção. É um dos aspectos da agricultura de precisão moderna (OLIVER, 2010), que visam aumentar a rentabilidade e proteção do meio ambiente, através da redução do risco de poluição de insumos químicos aplicados em concentrações maiores do que o ideal (BASSO et al., 2009, 2011).

Agricultura de Precisão (AP) requer uma avaliação mais precisa e com uma resolução reduzida da variação espacial (STAFFORD; BOLAM, 1998; STAFFORD, 2000; VRINDTS et al., 2003).

Dentro de uma zona de manejo, os efeitos uniforme de clima, solo e manejo agrícola são esperados na cultura (CASTRIGNANÒ et al., 2008; FRIDGEN et al., 2004; LARK, 1998). As zonas de manejo delineadas formam a base para taxas variáveis

de aplicação de insumos, uma vez que os fatores responsáveis pela variabilidade foram identificados.

Devido à 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. Várias técnicas de classificação são relatadas na literatura científica, entre as quais não são baseadas na minimização da variância dentro das unidades (FRAISSE et al., 2001; SILVERMAN, 1986; STAFFORD et al., 1998) e técnicas não paramétricas baseadas na estimativa da densidade multivariada (GUASTAFERRO et al., 2010).

Abordagem multivariada dentro da teoria geoestatística é preferível quando as relações entre as variáveis são dependentes de escala e podem ser associadas a diferentes fontes de variabilidade. Esta abordagem denomina-se Análise de Cokrigagem Fatorial (AKF) (MATHERON, 1982). Esta é uma combinação da tradicional Análise de Componentes Principais, para descrever a correlação de um conjunto de dados multivariado, e geoestatística levando em consideração a natureza regionalizada das variáveis.

Alguns fatores que afetam a resposta da cultura podem ter uma ação de curto alcance, enquanto outras operam em distâncias mais longas, portanto, a delimitação de zonas homogêneas deve ser dependente da escala. Uma importante vantagem da AKF é a possibilidade de extrair um número restrito de fatores dependentes da escala regionalizada que podem ser usado para apoiar a tomada de decisão na AP (CASA; CASTRIGNANÒ, 2008). Por estas razões AKF pode ser uma técnica útil para delinear zonas de manejo.

Castrignanò et al. (2000) investigaram a estrutura de correlação da escala dependente de algumas variáveis do solo por meio da AKF, a qual permitiu ao agricultor seguir as práticas de manejo da cultura, provido com a situação real do solo. Diacono et al. (2012) avaliaram a variabilidade espacial e temporal dos atributos relacionados à produtividade e qualidade da produção de trigo duro, utilizando Análise de Cokrigagem Fatorial.

De Benedetto et al. (2013) definiram abordagem multivariada e multisensores, combinando sensor de contato do solo (indução eletromagnética-IEM, Radar de Penetração no Solo-RPS, hiperespectral espectroscopia-HS e dados de sensoriamento remoto-RS), com objetivo em diferenciar um campo cultivável de 1,5 ha em

zonas homogêneas. Técnicas de fusão de dados de sensor foram necessários para analisar os dados em conjunto, a partir de diferentes fontes.

Aggelopoulou et al. (2013) utilizaram análise geoestatística multivariada para a delimitação das ZMs, dados da cultura e do solo, os dados foram coletados ao longo de três anos a partir de um projeto de AP em um pomar de maçã na Grécia.

4.5.1 Delimitação das zonas específicas de manejo

Delimitação das zonas específicas de manejo (ZEM) visa simplificar a representação espacial de variabilidade dentro do campo. O seu princípio consiste em dividir um campo em pequeno número de regiões. Essas regiões devem ser contíguas (uma região é um conjunto de pontos ligados), homogêneo (variabilidade intra zona é baixo) e distinta (variabilidade entre zonas é alta). Este processo permite que o agricultor adapte o manejo do campo para explicar as diferenças entre as principais zonas que podem existir dentro de um campo (ROUDIER et al., 2011).

Tradicionalmente, as áreas agrícolas têm sido manejadas como uma unidade única e contínua, embora muito já se saiba que as condições do solo, o desenvolvimento da cultura e a produtividade não são homogêneos dentro delas (SMITH, 1938). O reconhecimento e a análise da heterogeneidade e distribuição espacial destes parâmetros permitem uso mais adequado de insumos, mas também requerem a contribuição das tecnologias da informação espacial (LÓPEZ-LOZANO et al., 2010; MORAN et al., 1997; SEELAN et al., 2003) para definir ZEM.

Os métodos tradicionais para delimitar as zonas de manejo (ZMs) não consideram as relações espaciais entre as observações. ZEM trata os índices multivariados de variação espacial como contínua e em um conjunto de atributos geográfico espacial.

Morari et al. (2009) propuseram um procedimento, com base em geoestatística multivariada, para construir mapas de atributos do solo e classificar campos de vinhedo em zonas específicas de manejo. Diacono et al. (2013) propuseram uma abordagem combinada de geoestatística multivariada e método não paramétrico “cluster” para delinear ZMs em um campo de trigo duro no sul da Itália, sob a agricultura orgânica, usando as propriedades físicas e químicas do solo. Scudiero et al. (2013) aplicaram uma

combinação de condutividade elétrica aparente e NDVI para delinear ZEM em uma bacia costeira altamente contrastante, afetados pela intrusão de água salgada na margem sul da Lagoa de Veneza.

4.5.2 Fusão de dados

De acordo com Durrant-Whyte (2001), a fusão de dados é o processo de combinação de diferentes fontes de informações para proporcionar uma descrição completa e robusta de um ambiente ou processo de interesse. Fusão de dados tem um significado importante em qualquer aplicação com grandes quantidades de fontes de dados, que devem ser combinados e fundidos para obter informações de qualidade e com integridade adequada nas tomadas de decisões.

Com a ampla diversificação de fontes de dados fornecidos pela tecnologia moderna, tais como o sensoriamento remoto, os conjuntos de dados de sensores podem ser usados como informação auxiliar para completar uma variável alvo que é pouco amostrada. Dados de sensoriamento remoto e sensores de contato são muitas vezes maciça, com diferentes escalas espaciais e temporais, e sujeitos a vieses de erro de medição. Além disso, as diferenças entre os instrumentos estão sempre presente; no entanto, uma abordagem de fusão de dados pode tirar proveito de suas características complementares, por meio da combinação dos conjuntos de dados de sensores de um modo que seja estatisticamente robusto. Fusão de dados pode ser considerada como um problema de inferência: com dois ou mais conjuntos de dados de entrada heterogêneos, com diversas características estatísticas, de forma que a fusão venha estimar de forma otimizada, segundo o interesse, obter medidas de incerteza associada com estas inferências (BRAVERMAN et al., 2012).

O uso combinado de diferentes técnicas permitiu mapear distintas características espaciais e, em seguida, obter um conhecimento mais abrangente do sistema solo-planta-atmosfera, evitando o alto custo em amostragem intensiva. Atualmente, existem poucas publicações (CASTRIGNANÒ et al., 2012; GUASTAFERRO et al., 2010; TAYLOR et al., 2010) que integram diferentes camadas de informação, como fusão de dados de sensor de contato e/ou remoto com dados de solo, objetivando a delimitação de zonas homogêneas de manejo.

Alguns métodos têm sido propostos para incorporar informação secundária. Uma série de técnicas de interpolação híbridas, combinando técnica geoestatística de Cokrigagem com informações secundárias exaustivas, foram desenvolvidas e testadas para melhorar a precisão da variável primária (FROGBROOK; OLIVER, 2001; GOOVAERTS, 2000; McBRATNEY et al., 2000). Krigagem com deriva externa “external drift” (ROYLE; BERLINER, 1999; WACKERNAGEL, 2003) é uma técnica de geoestatística não estacionária, baseado num modelo que assume a distribuição condicional da variável primária e leva em conta a relação linear entre os dados primários e auxiliares. Modelos hierárquicos de regressão espacial (TRIAFANTAFILIS et al., 2000) e krigagem regressão (HENGGL et al., 2007) têm sido usados como uma alternativa para cokrigagem. Outra técnica seria uma aproximação da extensão da cokrigagem multivariada, conhecida como cokrigagem multicolocada, que provou ser adequada para fundir tipos de informações com resoluções diferentes (CASTRIGNANÒ et al., 2008).

Cokrigagem multicolocada (RIVOIRARD, 2001) faz uso de variável auxiliar em todos os pontos onde a variável destino está disponível e foi mostrado para permitir uma melhor estimativa de incertezas reduzidas, em comparação com a estimativa com base em observações de um único instrumentos (CASTRIGNANÒ et al., 2010; CHATTERJEE et al., 2010). Esta abordagem baseia-se na disponibilidade de variáveis auxiliares em todos os locais em que a variável de interesse está sendo avaliada e assume que as relações entre as variáveis auxiliares e as observações primárias permanecem constantes ao longo da região examinada.

Cokrigagem multicolocada combina e reforça, de forma eficaz, o valor das observações terrestres da variável de interesse com os diferentes conjuntos de dados de sensores (CASTRIGNANÒ et al., 2012). Ao fundir essas medições com observações terrestres, utilizando técnicas de geoestatística multivariada, é possível obter estimativas mais confiáveis de propriedades do solo em diferentes escalas espaciais, que podem aumentar a eficácia do manejo em zonas específicas de manejo (ZEM).

5 MATERIAL E MÉTODOS

5.1 Caracterização da área do estudo

Os dados utilizados nesta pesquisa foram obtidos das áreas de produção de cana-de-açúcar da Usina Açucareira São Manoel S.A. 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 (Figura 5).

A área de estudo encontra-se próximo às coordenadas de 22° 76' de latitude sul e 48° 42' 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 (NASCIMENTO; PEREIRA, 1988).

A variedade de cana-de-açúcar em estudo foi a RB86 7515, de alta precocidade em maturação e boa soqueira.

O solo LATOSSOLO VERMELHO Distroférico (LRdf) foi classificado de acordo com os padrões da EMBRAPA (2013), caracterizados por um horizonte superficial variando com teores médios de argila de 254 e 259 g kg⁻¹ nas profundidades de 0-0,2 m e 0,2-0,4 m, respectivamente.




Figura 5. Localização das áreas produtoras de cana-de-açúcar da Usina Açucareira São Manoel S.A. São Paulo.

A primeira colheita mecânica foi realizada em maio de 2011, com produtividade média de $111,3 \text{ t ha}^{-1}$ em colmos. A segunda colheita, também mecânica, foi realizada em maior de 2012, com produtividade média de $99,0 \text{ t ha}^{-1}$ em colmos. A terceira e quarta colheita também mecânica, com produtividade de $79,0$ e $65,0 \text{ t ha}^{-1}$ respectivamente. O sistema de colheita mecânica com cana crua, possibilitou que a palhada fosse mantida em superfície.

5.2 Dados climáticos

Dados climáticos de chuva e temperatura do ar, relativa ao ciclo da cana-de-açúcar 2013/2014 da Usina São Manoel foram obtidos a partir das estações meteorológicas convencionais de superfície do Centro Integrado de Informação Agrometeorológica (CIIAGRO, 2014), localizado na cidade de São Manuel-São Paulo.

A plotagem dos dados meteorológicos de precipitação total mensal (mm) e temperatura média do ar ($^{\circ}\text{C}$) está exposta na Figura 6.

As maiores precipitações mensais durante o período de estudo foram 188,0 mm e 152,2 mm em janeiro e fevereiro 2014, respectivamente, enquanto no inverno os meses de junho e agosto foram secos com 15,0 mm e 1,0 mm, respectivamente. A temperatura média durante os meses mais frio (maio-agosto) está entre 18,8 °C e 18,4 °C e entre 24,6 °C e 25,5 °C nos meses mais quentes (dezembro-fevereiro).




Figura 6. A precipitação total (mm) e temperatura (°C) média mensais registrados pela estação agrometeorológica de São Manuel –SP, para o ciclo da cana-de-açúcar 2013/2014.

Fonte: Centro Integrado De Informações Agrometeorológicas (CIIAGRO) 2014.

As maiores precipitações mensais durante o período de estudo foram 188,0 mm e 152,2 mm em janeiro e fevereiro 2014, respectivamente, enquanto no inverno os meses de junho e agosto foram secos com 15,0 mm e 1,0 mm, respectivamente. A temperatura média durante os meses mais frio (maio-agosto) está entre 18,8 °C e 18,4 °C e entre 24,6 °C e 25,5 °C nos meses mais quentes (dezembro-fevereiro).

5.3 Amostragem do solo

A grade de amostragem foi definida dentro do perímetro de campo de cana-de-açúcar com uma área de 66,87 ha, utilizando o programa de Falker Map (2011). O delineamento amostral consistiu de células regulares de tamanho de 1 ha, portanto, a densidade de amostragem foi uniforme totalizando 71 amostras (Figura 7). De acordo com

a literatura, esta é a densidade de amostragem mínima de solo para Agricultura de Precisão no Brasil (VIEIRA, 1995; RIBEIRO JUNIOR, 1995; MOLIN, 2001; ROSSATO, 2011) e também sendo a mais rentável para realização do estudo.




Figura 7. Locais das amostras de solo em uma malha regular de 100 m em campo de cana-de-açúcar.

A amostragem foi realizada nos meses de setembro e outubro de 2013, com um trado tipo holandês e anéis volumétricos (diâmetro de 0,05 m e 0,05 m de altura) nas profundidades de 0-0,2 m e 0,2-0,4 m.

5.4 Análises do solo em laboratório

As amostras do solo foram enviadas ao Laboratório de Solos, Universidade Estadual Paulista - Faculdade de Ciências Agrônomicas/UNESP - Botucatu - São Paulo (Brasil).

Os atributos do solo analisados no estudo foram: densidade do solo ($D_s\text{-g cm}^{-3}$), argila (g kg^{-1}), silte (g kg^{-1}), capacidade de campo ($\text{CC-dm}^3 \text{ dm}^{-3}$), matéria orgânica (MO-g dm^{-3}), capacidade troca catiônica ($\text{CTC-\%}$), cálcio (Ca-mmol dm^{-3}),

potássio (K-mmol dm⁻³), magnésio (Mg-mmol dm⁻³), enxofre (S-mg dm⁻³), fósforo (P-mg dm⁻³) e pH, de acordo com EMBRAPA (1997).

A capacidade de campo foi determinada pelo método da mesa de tensão, com amostras indeformadas em anéis volumétricos à 0,006 MPa, de acordo com a EMBRAPA (1997).

Distribuição granulométrica do solo (argila, areia e silte) foi determinada com o método da pipeta. Para esta análise foram utilizadas as amostras deformadas coletadas nas duas profundidades, de acordo com a EMBRAPA (1997).

A matéria orgânica foi determinada pela multiplicação 1,724 x carbono orgânico (CO). Este factor multiplicativo é assumido porque, na composição média de húmus, o carbono participa com 58% em peso da matéria orgânica. O método utilizado para medir o CO está de acordo com a EMBRAPA (1997).

Condutividade elétrica foi determinada usando o método condutivimétrico que se baseia na medição da resistência da amostra. A medida é dada como condutância específica (condutividade a 25 °C) em micro Siemens (μS cm⁻¹), de acordo com (PINTO, 2007).

5.5 Imagem Landsat-8

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. A cena foi adquirida de forma gratuita no portal GLOVIS: The USGS Global Visualization Viewer.

A plataforma Landsat-8 opera com dois instrumentos (Tabela 3), sendo a primeiro, Operational Land Imager (OLI), com nove bandas espectrais, incluindo a banda pancromática e o segundo Thermal Infrared Sensor (TIRS), com duas bandas termais (USGS, 2013). Todas as faixas foram processadas e fornecidas com 30 m de resolução espacial, para homogeneizar os dados.

Tabela 3. Landsat 8 Operational Land Imager (OLI) e Thermal Infrared Sensor (TIRS)

Instrumentos	Bandas	Comprimento de onda (micrômetros)	Resolução (metros)
Landsat 8 Operational Land Imager (OLI) e Thermal Infrared Sensor (TIRS)	Banda 1- Coastal aerosol	0,43 - 0,45	30
	Banda 2- Azul	0,45 - 0,51	30
	Banda 3- Verde	0,53 - 0,59	30
	Banda 4- Vermelho	0,64 - 0,67	30
	Banda 5- Infravermelho próximo (NIR)	0,85 - 0,88	30
	Banda 6- SWIR 1	1,57 - 1,65	30
	Banda 7- SWIR 2	2,11 - 2,29	30
	Banda 8- Pancromática	0,50 - 0,68	15
	Banda 9- Cirrus	1,36 - 1,38	30
	Banda 10- termal infravermelho (TIRS)	10,60 - 11,19	100* (30)
	Banda 11- termal infravermelho (TIRS) 1	11,50 - 12,51	100* (30)

* TIRS bandas foram adquiridas com resolução de 100 metros, mas foram reamostrados para 30 metros em dados de entrega (USGS, 2013).

5.6 Escolha da imagem Landsat-8 para o estudo

A imagem escolhida foi no período de máximo crescimento da cultura (parâmetros biofísicos e biomassa da vegetação), no mês de verão janeiro, o que é fundamental para determinar a produtividade final da cana-de-açúcar (Tabela 4).

A cana-de-açúcar (*Saccharum spp.*) é uma planta perene, de clima tropical e subtropical e pertencente à família Poaceae (VIDAL; TREZZI, 2011). Possui metabolismo C_4 , sendo classificada dentre as de maior eficiência fotossintética e de elevada eficiência no uso de água (CASA GRANDE; VASCONCELOS, 2008). Vários fatores podem causar alterações no metabolismo da planta e em características externas, especialmente sobre as folhas. Portanto, essas características devem influenciar a resposta espectral do dossel de cana.

Tabela 4. Estádios fenológicos do crescimento da cana-de-açúcar

Tabela 4. Estádios fenológicos do crescimento da cana-de-açúcar																				
Cana-de-açúcar	Fev	Mar	Abr	Maio	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Maio	Jun	Jul	Ago	Set
CS 12m				R	1	2	3	4	5	6	7	8	9	10	11	12	C			
Estágio Fenológico					Período de repouso fisiológico					Período de máximo desenvolvimento					Período máxima maturação					
Estações	Verão / Outono				Inverno / Primavera					Verão / Outono					Inverno / Primavera					
CS= Cana Soca Ago - meses de colheita Jan - sem colheita R= Rebrotas C= Colheita CS 12m = RB867515 (variedade estudada)																				

5.7 Pré-processamento da imagem Landsat-8

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, registrado na Equação 4.

$$L = M_L Q_{cal} + A_L \quad (4)$$

onde:

L_{λ} =TOA radiância espectral ($W m^{-2} sr^{-1} \mu m^{-1}$);

M_L =banda específica fator redimensionado multiplicador a partir dos metadados Radiância_Mult_Banda_ L , onde L é o número da banda;

A_L =banda específica fator escalonado aditivo a partir de metadados da Radiância_Add_Banda_ L , onde L é o número da banda;

Q_{cal} =produto quantificado e calibrado padrão em valores de pixel (ND).

A banda OLI também foi convertida para TOA reflectância planetária através dos coeficientes de reflectância redimensionado fornecidos no (arquivo MTL). Para converter valores digitais OLI para reflectância TOA, foi usada a Equação 5:

$$\rho' = M Q_{cal} + A \quad (5)$$

onde:

ρ_{λ}' = TOA reflectância planetária, sem correção para o ângulo solar ($\text{W m}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$);

M_p = banda específica do fator multiplicador redimensionando da reflectância_Mult_Banda_p, onde p é o número da banda;

A_p = banda específica do fator aditivo redimensionando da reflectância _Add_Band_p, onde p é o número da banda;

Q_{cal} = Produto padrão quantificado e calibrado dos valores dos pixels (DN).

5.8 Análise geoestatística multivariada

A análise geoestatística multivariada foi dividida em duas partes:

Parte A: destina-se a delimitação de duas zonas homogêneas de manejo com a utilização das variáveis químicas e físicas do solo e dados de radiância espectral do Landsat-8 (Figura 8).

Parte B: objetivo de mostrar o potencial da fusão entre os dados do solo e os dados espectrais do Landsat-8 para melhorar a delimitação de zonas homogêneas de manejo (Figura 9).

Para todas as variáveis foi verificada por meio de análise descritiva prévia estacionariedade intrínseca. As análises geoestatística multivariada foram realizadas com o pacote do programa ISATIS (GEOVARIANCES, 2014).




Figura 8. Fluxograma da parte A, análise geoestatística multivariada aplicada em variáveis de solo e dados de radiância espectral do Landsat-8.




Figura 9. Fluxograma da segunda parte B que mostram os dados no processo de fusão.

5.9 Aquisição dos dados

Foram adquiridos dois tipos diferentes de dados, como a seguir: 1) amostras de solo coletadas no gride de 100 m x 100 m. As variáveis de solo foram: pH do solo, condutividade elétrica, densidade do solo, capacidade de campo, fósforo extraível, distribuição de tamanho de partículas (argila e silte), cátions trocáveis (Ca, Mg, K e S), capacidade troca catiônica e matéria orgânica; 2) dados de radiância espectral do satélite Landsat-8. As bandas espectrais foram: banda 1 - aerosol 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. Na fusão dos dados todas as bandas espectrais foram usadas como variáveis auxiliares.

Três Modelos Lineares de Corregionalização (MLC) foram desenvolvidos: o primeiro para as variáveis de solo, o segundo para os dados espectrais e o terceiro para a fusão de dados solo e bandas espectrais. O conjunto de dados espacial multivariado foi analisado por: cokrigagem e cokrigagem multicolocada para produzir os mapas temáticos das variáveis em estudo. Cokrigagem fatorial e cokrigagem multicolocada fatorial foram utilizadas para determinar fatores regionalizados em escala dependente.

Parte A

5.9.1 Modelagem Anamorfose Gaussiana

A dificuldade na aplicação prática da abordagem multivariada ocorre quando as variáveis são de magnitude diferente. A solução foi padronizar as variáveis individuais de solo e espectral dando a cada uma, uma média de zero e uma variância de unidade um. A modelagem do variograma, pela presença de outliers na distribuição dos dados, torna-se mais complexa. Neste caso, foi melhor realizar uma normalização dos dados por meio da Modelagem Anamorfose Gaussiana. Anamorfose Gaussiana é uma função matemática que transforma uma variável Y com uma distribuição qualquer em distribuição de Gauss padronizada: $Z = \frac{Y - \mu}{\sigma}$ (Y). Uma vez que esta função precisa ser conhecida pela distribuição de Gauss, uma modelagem é necessária. Isto foi feito ajustando a distribuição de Gauss à uma expansão polinomial de Chilès e Delfiner (1999), de acordo com Equação 6:

$$\Phi(Y) = \sum \Psi_i H_i(Y) \quad (6)$$

onde:

$H_i(Y)$ polinômios de Hermite. Na prática, a expansão polinomial é truncada à uma ordem finita e tende a adquirir valores dentro do intervalo definido pelo valores mínimo e máximo da amostra (WACKERNAGEL, 2003). Foram ajustados os modelos, em seguida, foram calculados os coeficientes Ψ_i da expansão, de modo a transformar as variáveis brutas do solo e das bandas em Gaussiana e cada função anamorfose foi invertida: $Y = \Phi^{-1}(Z)$. Esta inversão, fora do intervalo em que a função não é estritamente crescente para todos os valores de Y , foi realizada utilizando-se uma interpolação linear (WACKERNAGEL, 2003).

5.9.2 Modelo Linear de Correogionalização (MLC)

Adotando um modelo Gaussiano, um modelo linear de correogionalização (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 e, posteriormente, a cokrigagem ordinária (GOOVAERTS, 1997) foi aplicada como condicional estimador expectativa. Finalmente, as estimativas foram retransformado para os valores brutos das variáveis através das funções anamorfose previamente calculados.

A 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 do solo e as bandas espectrais 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 7:

$$\Gamma(\mathbf{h}) = \sum_{u=1}^{N_s} B^u g^u(\mathbf{h}) \quad (7)$$

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 correção regionalização 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).

5.9.3 Cokrigagem

O procedimento de Cokrigagem é uma extensão natural da Krigagem Ordinária quando um conjunto de dados multivariados está disponível. Cokrigagem Ordinária (CKO) é um dos métodos mais básicos de cokrigagem, qual assume as médias locais das variáveis sendo constantes, mas desconhecidas (GOOVAERTS, 1998).

CKO é uma combinação linear através dos pesos λ^i_α dos dados de diferentes variáveis localizados nos pontos da amostra em uma vizinhança do ponto $\mathbf{x}_0$ sem amostragem. O estimador é definido pela Equação 8:

$$\mathbf{z}^*_{i0}(\mathbf{x}_0) = \sum_{i=1}^n \sum_{\alpha=1}^{ni} \lambda^i_\alpha \mathbf{z}_i(\mathbf{x}_\alpha) \quad (8)$$

onde:

o índice i_0 refere-se a uma variável particular do conjunto de variáveis N .

Por último foi feita uma retransformação dos mapas estimados através dos dados brutos utilizando o modelo matemático calculado na Modelagem Anamorfose Gaussiana.

5.9.4 Cokrigagem Fatorial (CKF)

O mapeamento dos fatores regionalizados fornece uma ilustração do comportamento e das relações entre as variáveis em diferentes escalas espaciais. Foi aplicado na estimativa das variáveis gaussianas do solo e dados de reflectância a partir dos fatores regionalizadas. A estimativa dos fatores foi realizada por um sistema de

cokrigagem modificado, como descrito por Wackernagel (1988) e Castrignanò 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.

Parte B

Antes da aplicação da técnica de fusão de dados foi aplicada a análise de componentes principais (método Varimax), para reduzir a dimensionalidade do banco de dados entre dados de solo nas duas profundidades e dados espectrais das bandas.

5.9.5 Análise de componentes principais (método Varimax)

Análise de Componentes Principais (ACP) permitiu acessar a associação entre as variáveis, reduzindo a dimensionalidade do conjunto de dados. Isto foi obtido através da diagonalização da matriz de correlação dos dados, o qual transforma as variáveis originais não correlacionadas em ortogonais e os pesos das combinações lineares das variáveis originais chamam-se Componentes Principais (CPs). Os autovalores das CPs são uma medida de sua variância associada e a participação das variáveis originais nas CPs é dada pelos carregamentos com as observações individuais transformadas chamadas de pontuação.

Os valores de CPs foram reduzidos por meio de uma rotação dos autovalores (Varimax), segundo Knudson et al. (1977), com aumento da participação das variáveis com maior contribuição e reduzindo, simultaneamente, as variáveis com menor contribuição, o procedimento foi realizado no programa SAS/STAT (SAS^R versão 9.3, 2013). Por meio desse método, os CPs rotacionados obtidos pelo método Varimax (VFs) foram obtidos para as variáveis originais que participam de forma mais efetiva. Dessa forma, o número de variáveis originais que contribuem para cada VF foi reduzido com perda de ortogonalidade.

5.9.6 Cokrigagem em bloco

Os dados espectrais da banda 3 - Verde, banda 5 - infravermelho próximo (NIR), banda 6 - SWIR 1, banda 7 - SWIR 2, banda 10 e 11- infravermelha térmica foram utilizados como atributos secundários para criar o modelo de fusão.

Foi utilizada a cokrigagem em bloco para os parâmetros do solo (dados pontuais) para calcular as médias locais para áreas que são maiores do que o gride inicial da amostragem de solo, ou seja, o tamanho do pixel de 30x30 m da imagem do Landsat 8.

Para calcular as médias locais para áreas ou volumes que são maiores do que as unidades (suportes = bandas espectrais) que foram inicialmente incluídas na amostra, krigagem em bloco foi empregada. Ela modificou as equações de krigagem pontuais para obter uma estimativa média de z em uma área discreta ou bloco B . O valor médio de z sobre um bloco B é dada pela Equação 9:

$$\mathbf{z}(\mathbf{x}_B) = \int_B \frac{\mathbf{z}(\mathbf{x})d\mathbf{x}}{areaB} \quad (9)$$

E é estimado pela Equação 10:

$$\mathbf{z}^*(\mathbf{x}_B) = \sum_{i=1}^N \lambda_i \mathbf{z}(\mathbf{x}_i) \quad (10)$$

Com $\sum_{i=1}^N \lambda_i = 1$, como por krigagem pontual. Embora a Equação 10 é idêntica a equação da krigagem, os pesos λ_i são calculados através das variâncias médias entre cada ponto de todos os pontos dentro do bloco.

Na cokrigagem em bloco, o sistema de Cokrigagem Ordinária pode ser reescrita, mas o lado direito contém o variograma médio sobre os pontos dentro do bloco B .

Para produzir a correionalização (fusão) do conjunto de dados, as bandas espectrais foram adquiridas nos locais das amostras do solo usando Cokrigagem Ordinária. A fusão do conjunto de dados, variáveis de solo e bandas espectrais foram interpolados usando Cokrigagem Multi Colocada (COKMC).

5.9.7 Cokrigagem Multi Colocada

Cokrigagem ordinária permite integrar informações entre dados primários esparsos, dados de solo, a dados secundários de alta resolução, dados espectrais, através da abordagem cokrigagem colocada, onde a contribuição da variável secundária à estimativa cokrigagem depende apenas do dado no nó de destino (GOOVAERTS, 1997).

A cokrigagem ordinária usa-se toda a informação secundária contida dentro da vizinhança de busca, que pode levar a uma solução praticamente intratável devido a presença de muita informação. A cokrigagem colocada foi modificada para que a variável secundária seja usada no local de destino e também em todos os locais onde a variável principal é definida dentro da vizinhança. Esta versão modificada, também conhecida como "Cokrigagem Multi colocada" (RIVOIRARD, 2001), é menos precisa do que a cokrigagem ordinária, porque o ponto secundário colocado de referência tende a rastrear a influência dos dados secundários mais distantes, há realmente pouca perda de informação. A vantagem da técnica de cokrigagem multi colocada é menos exigente computacionalmente e demorada em comparação com cokrigagem ordinária. Em cokrigagem multi colocada diferentemente do que em cokrigagem colocada, a influência da variável secundária sobre a variável principal é explicitamente levado em conta ao estimar o variograma direto e cruzado das variáveis secundárias. Esta solução geralmente produz resultados confiáveis e estáveis (CASTRIGNANÒ et al., 2009, 2012)

5.9.8 Análise de componentes principais

Em geoestatística Análise de Componentes Principais (ACP) decompõe cada matriz de correionalização $\mathbf{B}^u$ (Equação 11) (a matriz do patamar dos variogramas na escala espacial u) nas matrizes de autovalores e autovetores (WACKERNAGEL, 2003):

$$\mathbf{B}^u = \mathbf{Q}^u \mathbf{\Lambda}^u \mathbf{Q}^{uT} = \left(\mathbf{Q}^u \sqrt{\mathbf{\Lambda}^u} \right) \left(\mathbf{Q}^u \sqrt{\mathbf{\Lambda}^u} \right)^T = \mathbf{A}^u \mathbf{A}^{uT} \quad (11)$$

onde:

Q^u é a matriz de autovetores, ou seja, os fatores regionalizados $Y_v^u(x)$, e Λ^u é a matriz diagonal dos autovalores para cada escala espacial u ; $A^u = Q^u \sqrt{\Lambda^u}$ é a matriz de ordem $n \times n$ dos coeficientes de transformação a_{iv}^u . Os coeficientes de transformação a_{iv}^u na matriz A^u correspondem as covariâncias entre as variáveis originais $Z_i(x)$ e os fatores regionalizados $Y_v^u(x)$. Autovetores correspondentes aos autovalores superiores a um são mantidos porque a sua variação é maior do que cada variável padronizada para variância unitária.

Esta abordagem decompõe o conjunto de funções aleatório originais de segunda ordem estacionárias $\{Z_i(x); i = 1, n\}$ em conjuntos de componentes espacialmente não correlacionados, relacionado a cada escala espacial u ; cada componente pode propriamente ser representado como um conjunto de fatores não correlacionados $\{Y_v^u(x); v = 1, \dots, n; u = 1, \dots, N_s\}$ com coeficientes de transformação a_{iv}^u , combinando o espaço com a decomposição multivariada segundo Equação 12 (WACKERNAGEL, 2003).

$$Z_i(x) = \sum_{u=1}^{N_s} \sum_{v=1}^n a_{iv}^u Y_v^u(x) \quad (12)$$

5.9.9 Cokrigagem Multi-colocada fatorial

Depois da interpolação, o mapeamento dos fatores regionalizados $Y_v^u(x)$ auxilia a divulgar o comportamento e as relações entre as funções aleatórias em diferentes escalas espaciais.

5.10 Validação cruzada

A adequação do modelo dos variogramas escolhidos foi testada pela validação cruzada. Isso envolveu a exclusão de cada amostra n tornar-se elas então em krigagem (z^*) independentemente de todos os outros pontos na vizinhança estimada. Além disso, o procedimento de krigagem produziu a variância dessa estimativa (σ^2).

O erro experimental, isto é, a diferença entre valor estimado e o verdadeiro ($z^* - z$), foi dimensionado pelo desvio padrão previsto da estimativa (σ)

produzindo o erro normalizado. Esta quantidade foi uma variável normal com média zero, portanto, ela pode avaliar a qualidade do ajuste. Se o valor for superior a 2,5 em valor absoluto, encontra-se fora do intervalo de confiança de 99% de uma distribuição normal e os pontos de dados correspondentes é chamado *outlier*. Os pontos para os quais o erro padronizado encontra-se dentro do intervalo $[-2,5; 2,5]$ são chamados geralmente de robusto.

O erro experimental foi avaliado por meio das seguintes estatísticas:

$$✓ \text{ Média do erro padronizado } \frac{1}{N} \sum_{i=1}^N \left(\frac{z(x_i) - z^*(x_i)}{\sigma_i} \right)$$

$$✓ \text{ Variância do erro padronizado } \frac{1}{N} \sum_{i=1}^N \left(\frac{z(x_i) - z^*(x_i)}{\sigma_i} \right)^2$$

onde:

N designa o número de pontos de dados. A média do erro padronizado mede o grau de viés, o qual deve ser o mais próximo de zero possível. A variância do erro padronizado corresponde à relação entre a variância experimental e teórica e devem, então, estar próximo de um, uma tolerância típica é usada $\pm 1 \pm 3\sqrt{2/N}$ (CHILÈS; DELFINER, 2012).

6 RESULTADOS E DISCUSSÃO

A análise geoestatística multivariada foi dividida em três partes: a) delimitação de zonas de manejo utilizando as variáveis químicas e físicas do solo; b) delimitação de zonas de manejo por meio de dados da radiância espectral do Landsat-8 e c) delimitação de zonas homogêneas de manejo por meio da fusão dos dados do solo e dos dados espectrais do Landsat-8.

6.1 Delimitação das zonas de manejo (ZM_s) utilizando as variáveis de solo

6.1.1 Análise descritiva dos dados

A estatística descritiva das propriedades física e químicas do solo na camada de 0-0,2 m e 0,2-0,4 m está resumida na Tabela 5. É evidente que algumas distribuições de dados do solo mostram-se sem distribuição normal, exceto Ca, Condutividade elétrica (CE), Mg, P e S.

Uma dificuldade em aplicar uma abordagem multivariada ocorre quando as variáveis são de tamanhos diferentes. A modelagem do variograma é ainda mais complicada pela presença de *outliers* em distribuições de dados altamente enviesados. Neste caso, foi realizada a normalização dos dados pela Modelagem Anamorfose Gaussiana, e padronizados para média zero e variância um.

Tabela 5. Estatística descritiva das propriedades físico-químicas do solo

Variáveis	Min	Max	Média	Desvio Padrão	Coef. de Assimetria	Coef. de Curtose
profundidade 0-0,2 m						
Ds (g cm ⁻³)	1,42	1,91	1,64	0,10	0,04	2,56
Argila (g kg ⁻¹)	75,00	415,00	258,66	73,74	-0,09	2,87
Silte (g kg ⁻¹)	13,00	107,00	57,24	22,10	0,22	2,30
CC (dm ³ dm ⁻³)	0,19	0,33	0,26	0,03	0,16	2,44
CTC (%)	38,09	89,43	62,60	12,62	0,05	2,11
Ca (mmolc dm ⁻³)	11,22	45,36	24,94	8,48	0,65	2,50
CE (μs cm ⁻¹)	332,0	1941,0	844,27	368,9	0,64	2,88
K (mmolc dm ⁻³)	0,66	6,69	3,20	1,46	0,43	2,62
Mg (mmolc dm ⁻³)	3,79	16,42	8,80	3,06	0,66	2,55
MO (g dm ⁻³)	6,01	19,90	14,71	3,28	-0,49	2,37
P (mg dm ⁻³)	2,83	16,86	8,65	3,22	0,92	3,29
S (mg dm ⁻³)	6,33	82,99	33,33	20,29	0,68	2,49
pH	4,09	6,40	5,35	0,54	-0,01	2,35
profundidade 0,2-0,4 m						
Ds (g cm ⁻³)	1,47	1,79	1,66	0,08	-0,43	2,58
Argila (g kg ⁻¹)	75,00	412,00	261,49	74,20	-0,11	2,55
Silte (g kg ⁻¹)	13,00	125,00	60,80	23,76	0,40	2,81
CC (dm ³ dm ⁻³)	0,18	0,32	0,25	0,03	0,11	2,89
CTC (%)	41,22	99,92	64,65	14,62	0,33	2,14
Ca (mmolc dm ⁻³)	8,16	40,25	21,57	8,26	0,64	2,74
CE (μs cm ⁻¹)	223,0	1647,0	734,97	342,4	0,65	2,73
K (mmolc dm ⁻³)	0,54	6,45	2,84	1,53	0,60	2,55
Mg (mmolc dm ⁻³)	3,16	14,89	7,60	3,14	0,69	2,52
MO (g dm ⁻³)	7,55	22,04	14,26	3,41	0,30	2,69
P (mg dm ⁻³)	2,59	17,35	8,46	3,70	0,69	2,77
S (mg dm ⁻³)	6,48	92,95	34,33	20,13	0,68	2,72
pH	4,03	6,33	5,09	0,58	0,28	2,27

Densidade do solo-Ds, capacidade de campo-CC, matéria orgânica MO, capacidade troca catiônica-CTC, cálcio-Ca, potássio-K, magnésio-Mg, enxofre-S, fósforo-P.

Na primeira análise, não houve diferença distinta nos valores médios das variáveis entre as duas profundidades. Portanto, para delimitação das Zonas de Manejo (ZMs), decidiu-se selecionar apenas as variáveis da primeira profundidade (0-0,2 m), devido à semelhança dos dados em profundidade.

Através dos gráficos Quantil - Quantil (Figuras 10, 11 e 12) foi possível comparar as diferenças nas distribuições entre duas profundidades (0-0,2 m e 0,2-0,4 m). Os dados de distribuição que estão plotados sobre a linha $y = x$, isto significa que as duas populações estatísticas comparadas são homogêneas.




Figura 10. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m.




Figura 11. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m. (Continuação).




Figura 12. Q-Q gráficos dos dados das propriedades físico-químicas do solo nas profundidades 0-0,2 m e 0,20-0,4 m.

Os coeficientes de correlação de Pearson estão dispostos na Tabela 6 para todas variáveis físicas e químicas do solo, utilizada no modelo. A densidade do solo (Ds) foi correlacionada negativamente com capacidade de campo (CC); Ca positivamente com Mg, P, CC, argila, silte e pH; argila positivamente com Mg, K, S, MO, CC e silte e negativamente com o pH; CE positivamente com K e S; CC positivamente com K, S, MO e silte; pH positivamente com Ca, Mg e P e foi correlacionado negativamente com argila, MO, S e silte. É comumente conhecido que a matéria orgânica do solo e argila são materiais coloidais com grande área de superfície que aumenta a capacidade de troca de cátions do solo, o que explica a correlação positiva entre o CE, argila, MO e silte.

Tabela 6. Matriz de correlação das das propriedades físicas e químicas do solo na profundidade 0-0,2 m

Variáveis	Ds	CTC	Ca	Argila	CE	CC	K	Mg	MO	P	S	Silte	pH
Ds	1,00	-0,21	-0,20	-0,23	-0,10	-0,50	-0,18	-0,05	-0,11	-0,17	-0,15	-0,06	-0,14
CTC		1,00	0,58	0,80	0,19	0,53	0,36	0,54	0,57	0,03	0,26	0,66	-0,19
Ca			1,00	0,33	0,09	0,29	0,07	0,81	0,21	0,30	-0,13	0,35	0,61
Argila				1,00	0,09	0,60	0,28	0,39	0,57	-0,13	0,28	0,65	-0,38
CE					1,00	0,10	0,50	0,08	0,09	-0,06	0,71	0,22	0,01
CC						1,00	0,26	0,20	0,34	0,09	0,26	0,43	-0,07
K							1,00	0,14	0,23	0,17	0,29	0,07	-0,10
Mg								1,00	0,10	0,12	-0,15	0,38	0,40
MO									1,00	-0,08	0,24	0,46	-0,31
P										1,00	-0,19	-0,24	0,46
S											1,00	0,35	-0,32
Silte												1,00	-0,27
pH													1,00

*Todos os coeficientes de correlação > 0,26 são significativos para p 0,05 de probabilidade.

6.1.2 Análise de correionalização

A análise da estatística clássica não pode separar as diversas fontes de variabilidade espacial em escalas diferentes, que afetam a fertilidade do solo, portanto, foi aplicada a Análise de Krigagem Fatorial (AKF) para analisar a estrutura espacial aninhada do conjunto de dados multivariados.

O variograma experimental foi desenvolvido para as propriedades do solo, com suas estruturas básicas (patamar, alcance e efeito pepita). Os valores dos parâmetros de todos os variogramas isotrópicos para as variáveis foram relacionados: espaçamento amostral de 100 m, tamanho do passo (*lag*) 75 m e números de passos (*lag*) 7 (Figura 11).

Os variogramas diretos e cruzados foram modelados para o alcance de 380 m nas estruturas espaciais: efeito pepita e modelo esférico. O ajuste do Modelo Linear de Correionalização (MLC) foi verificado com o teste de validação cruzada, com a média e a variância dos valores do erro padronizado próximo de zero e um, respectivamente, para as variáveis obtidas pela transformação gaussiana.

A primeira estrutura observada foi o efeito pepita, compreendendo a variação espacial que ocorrem às distâncias menores do que a escala de amostragem de 100 m ou o erro de medição. Esta estrutura pode ser vista em todos os variogramas e foi predominante para Ds, CC e K. A segunda estrutura reflete um processo transitivo do tamanho da escala de aproximadamente 380 m.

No entanto, a inspeção visual da matriz dos variogramas experimentais com o modelo ajustado foi verificada (Figuras 13, 14 e 15). Para avaliar a robustez da relação espacial entre as variáveis foi utilizada a distância entre o variograma cruzado experimental com o modelo tracejado. Quanto menor a distância entre eles mais perfeita a correlação. Esta correlação é definida pela substituição dos patamares dos variogramas cruzados pela raiz quadrada do produto dos patamares dos correspondentes variogramas diretos (WACKERNAGEL, 2003).

Na Figura 11 estão expostos os variogramas experimentais (ponto) simples e cruzados, juntamente com o modelo linear de correionalização (modelo teórico). Todos os variogramas diretos aparecem bem estruturados, mas a maioria deles tem um grande componente de efeito pepita (componente aleatório). Nos variogramas

cruzados de argila, silte, MO e S são espacialmente correlacionados com a maioria das outras variáveis. A correlação espacial foi nula, por exemplo, para os pares das variáveis: P-MO, P-CE, silte-P, silte-Ds, pH-CC, argila-P, MO-Mg, CTC-Ds, K-Ca, entre outros.

O simples coeficiente de correlação tradicional produto-momento não revela a relação espacial real entre as variáveis porque (i) calcula modificações médias distintas nas estruturas de correlação devido as diferentes escalas espaciais, e (ii) inclui os erros de medição. Portanto, os coeficientes de correlação estrutural foram estimados, filtrando o efeito pepita, revelando correlações mais fortes ou mais fracas para os pares das variáveis, em comparação com os coeficientes de Pearson.

Altos coeficientes de correlação (Tabela 7) foram confirmados para os pares: CC-Ds (-0,75), P-Ds (-0,66), S-Ds (-0,61), Ca-CTC (-0,83), Argila-CTC (0,80), Mg-CTC (0,81), MO-CTC (0,62), silte-CTC (0,83), Mg-Ca (0,83), P-Ca (0,61), Ca-silte (0,64), Mg-argila (0,61), MO-argila (0,70), silte-argila (0,75), CC-CE (0,85), MO-CE (0,87), S-CE (0,94), K-CC (0,78), MO-CC (0,79), S-CC (0,91), MO-K (0,76), S-K (0,70), silte-Mg (0,74), S-MO (0,83) e pH-P (0,91). Essas relações estruturais denotam variabilidade semelhante para os pares de variáveis e sugerem a presença de fontes locais comuns de variação, provavelmente relacionados com a variação genética e com o manejo do solo.




Figura 13. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar.




Figura 14. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar (continuação).




Figura 15. Variogramas diretos e cruzados das propriedades físicas e químicas do solo na profundidade 0-0,2 m cultivado com cana-de-açúcar.

Tabela 7. Coeficiente estrutural de correlação das propriedades físicas e químicas do solo na profundidade 0-0,2 m na escala curta 380 m

Variáveis	Ds	CTC	Ca	Argila	CE	CC	K	Mg	MO	P	S	Silte	pH
Ds	1												
CTC	0,0587	1											
Ca	-0,0706	0,8328	1										
Argila	0,0433	0,8072	0,5496	1									
CE	-0,4511	0,5432	0,1766	0,4806	1								
CC	-0,7534	0,4281	0,2312	0,5100	0,8520	1							
K	-0,4774	0,2172	0,0128	0,4418	0,5603	0,7891	1						
Mg	0,4351	0,8150	0,8376	0,6113	0,0231	-0,1200	-0,2635	1					
MO	-0,2062	0,6219	0,1948	0,7064	0,8732	0,7908	0,7689	0,1284	1				
P	-0,6583	0,1993	0,6175	-0,0013	-0,0325	0,3242	0,1106	0,1398	-0,1734	1			
S	-0,6160	0,3900	0,1187	0,4030	0,9425	0,9191	0,7091	-0,1352	0,8358	0,0877	1		
Silte	0,048	0,8327	0,6456	0,7547	0,5688	0,3679	-0,0095	0,7483	0,5113	0,0178	0,4295	1	
pH	-0,3986	0,0076	0,5108	-0,1270	-0,4230	-0,0415	-0,1524	0,1627	-0,4982	0,9100	-0,3197	-0,1593	1

*Todos os coeficientes de correlação > 0,26 são significativos para p 0,05 de probabilidade.

6.1.3 Validação cruzada das variáveis de solo pela geoestatística multivariada

A adequação do modelo do variograma escolhido foi testada pela validação cruzada. Todas as variáveis que tiveram seu valor superior a 2,5 em valor absoluto encontraram-se fora do intervalo de confiança de 99% de uma distribuição normal e correspondente aos pontos amostrais chamado de *outlier*. Os pontos para os quais o erro padronizado encontrou-se dentro do intervalo $[-2,5; 2,5]$ foram chamados de robusto.

Os resultados do procedimento de validação cruzada são mostrados nas Figuras de 16 a 28. Cada figura é composta por três gráficos: histograma dos erros das estimativas padronizadas, que deve ser simétrico, centrado em zero e sem caudas longas (gráfico inferior esquerdo); diagrama de dispersão dos dados verdadeiros versus os valores estimados, que devem estar perto do primeiro bisetor (gráfico superior esquerdo); e diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados, o qual deve ser semelhante a uma nuvem redonda, simétrico ao eixo horizontal (gráfico inferior da direita).

O erro experimental foi avaliado por meio das seguintes estatísticas: a média do erro padronizado que mediu o grau de tendência “viés”, o qual deve ser o mais próximo de zero possível e a variância do erro padronizado, que correspondeu à relação entre as variações experimentais e teóricas e devem estar perto de um (1), existindo uma tolerância típica de $1 \pm 3\sqrt{2/N}$, para este estudo foi $N=70$, portanto a tolerância foi de $\pm 0,50$.

Os resultados de validação cruzada para D_s (Figura 16) mostram uma média correlação entre os valores verdadeiros e estimados, segundo o coeficiente de correlação (r) de 0,506. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é similar a uma “nuvem redonda” com valor de r 0,091. O histograma dos erros padronizados da estimativa não é simétrico, com um ponto encontrado fora do intervalo $(-2,5; 2,5)$, conhecido como *outlier*. A média do erro padronizado é próxima de zero (-0,029), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (1,017), o que significa que a estimativa resultante do modelo é precisa.




Figura 16. Validação cruzada para Ds.

Resultados da validação cruzada para capacidade de CTC (Figura 17) mostrou uma forte correlação entre os valores reais e os estimados com coeficiente de correlação (r) de 0,923. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados não apresentou correlação significativa com valor de r de 0,041. O histograma dos erros padronizados da estimativa mostrou alguns valores menores do que -2,5. A média do erro padronizado é próxima de zero (-0,001), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,989), o que significa que a estimação do modelo é precisa.




Figura 17. Validação cruzada para CTC.

Uma correlação muito forte entre os valores reais e estimados do cálcio foi encontrada com valor de r de 0,940 (Figura 18). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor de r de 0,073. O histograma dos erros padronizados da estimativa apresenta poucos valores superiores a 2,5. A média do erro padronizado é próxima de zero (0,013), o que significa que o modelo não é tendencioso e a variância de erro padronizado é (1,057), o que significa que o modelo da estimativa é exato.




Figura 18. Validação cruzada para Ca.

Uma alta correlação entre os valores reais e estimados da condutividade elétrica com valor de r de 0,865 (Figura 19). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor de r de 0,112. O histograma dos erros padronizados da estimativa é simétrico com todos os pontos dentro do intervalo $(-2,5; 2,5)$. A média do erro padronizado é próxima de zero ($-0,008$), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um ($1,002$), o que significa que a estimação do modelo é precisa.




Figura 19. Validação cruzada para CE.

Uma alta correlação entre os verdadeiros e estimados para os valores de capacidade de campo com o valor de r de 0,779 (Figura 20). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de r de 0,073. O histograma dos erros padronizados da estimativa é simétrico com apenas um valor menor do que -2,5. A média do erro padronizado é próxima de zero (-0,006), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,940), o que significa que a estimação do modelo é precisa.




Figura 20. Validação cruzada para CC.

Uma elevada correlação entre os valores verdadeiros e estimados do potássio é mostrado na (Figura 21) com valor de r de 0,736. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de r de 0,041. O histograma dos erros padronizados da estimativa apresenta apenas um valor maior que 2,5. A média do erro padronizado é próxima de zero (0,025), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (0,973), o que significa que a estimação do modelo é precisa.




Figura 21. Validação cruzada para K.

Para magnésio, há uma forte correlação (Figura 22) entre os valores reais e estimados com valor de r de 0,824. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor de r de 0,045. O histograma dos erros padronizados da estimativa tem um valor maior do que 2,5. O erro médio padronizado é próximo de zero (-0,015), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (1,029), o que significa que o modelo é bom para estimativas.




Figura 22. Validação cruzada para Mg.

Uma correlação alta entre os valores verdadeiros e estimados da matéria orgânica, com valor de r de 0,722 (Figura 23). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com valor de r de -0,005. O histograma dos erros padronizados da estimativa tem apenas um valor inferior a -2,5. O erro médio padronizado é próximo de zero (-0,054), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (0,897), o que significa que a estimativa do modelo é precisa.




Figura 23. Validação cruzada para MO.

Uma correlação média entre os valores verdadeiros e estimados de fósforo (Figura 24) é encontrada com valor de r de 0,600. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados mostra-se simétrico com valor de r de 0,099. O histograma dos erros padronizados da estimativa não apresenta *outliers*. O erro médio padronizado é próximo de zero (-0,024), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (1,044), o que significa que a estimação do modelo é precisa.




Figura 24. Validação cruzada para P.

Figura 25 apresenta uma forte correlação entre os valores reais e estimados do enxofre com valor de r de 0,843. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é simétrico com valor de r de 0,031. O histograma dos erros padronizados da estimativa tem dois valores menores que -2,5. O erro médio padronizado é próximo de zero (-0,010), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (1,119), dentro do intervalo da tolerância, o que significa que a estimação do modelo é precisa.




Figura 25. Validação cruzada para S.

Uma correlação muito forte entre os valores verdadeiros e estimados da argila com o valor de r de 0,900 (Figura 26). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de 0,071. O histograma dos erros padronizados da estimativa é simétrico com um valor inferior a -2,5 e um valor superior a 2,5. O erro médio padronizado é próximo de zero (-0,007), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é (1,0539), dentro do intervalo de tolerância, o que significa que a estimação do modelo é precisa.




Figura 26. Validação cruzada para argila.

Houve correlação muito forte entre os valores verdadeiros e estimados do pH com o valor de r de 0,925 (Figura 27). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de r de 0,002. O histograma dos erros padronizados da estimativa é simétrico, sem valores discrepantes. O erro médio padronizado é próximo de zero (-0,015), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (1.059), o que significa que a estimação do modelo é precisa.




Figura 27. Validação cruzada para pH.

Para silte, existe uma elevada correlação (Figura 28) entre os valores verdadeiros e estimados do silte com um valor de r de 0,779. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de r de 0,060. O histograma dos erros padronizados da estimativa mostra um valor inferior a -2,5. O erro médio padronizado é próximo de zero (0,018), o que significa que o modelo não é tendencioso, e a variância do erro padronizado é próxima de um (0,927), o que significa que o modelo é bom para estimativas teóricas.




Figura 28. Validação cruzada para silte.

6.1.4 Cokrigagem das variáveis do solo

Os mapas da cokrigagem utilizando a modelagem dos atributos de solo estão dispostos nas Figuras de 29 a 41.

O mapa da cokrigagem da Ds (Figura 29) mostra que os valores mais altos das estimativas estão concentrados na região central tendendo para o sul da área de estudo.




Figura 29. Interpolação por cokrigagem da Ds cultivado com cana-de-açúcar.

O mapa da variabilidade espacial da CTC (Figura 30) mostra um gradiente espacial distinto, aumentando de leste para oeste, com os valores mais altos no centro e ao longo da borda ocidental.




Figura 30. Interpolação por cokrigagem da CTC do solo cultivado com cana-de-açúcar.

O mapa da distribuição do Ca (Figura 31) mostra-se bastante semelhante ao anterior, o que permite deduzir que a geoquímica é dominada por Ca. Os menores teores de Ca foram encontrados no canto norte e leste da área.




Figura 31. Interpolação por cokrigagem do Ca no solo cultivado com cana-de-açúcar.

Diferentemente da distribuição das variáveis anteriores, o mapa da CE (Figura 32) mostra os valores menores na zona central do campo. Novamente os valores maiores ocorrem ao longo da borda oeste do campo.




Figura 32. Interpolação por cokrigagem do CE no solo cultivado com cana-de-açúcar.

O mapa da variabilidade da CC (Figura 33) mostra-se muito semelhante à distribuição da CE. Isso induz que as propriedades de salinidade do solo pode ter um impacto sobre suas características físicas (estrutura, porosidade e densidade do solo).




Figura 33. Interpolação por cokrigagem do CC no solo cultivado com cana-de-açúcar.

O mapa da distribuição espacial do K (Figura 34) mostra uma ampla zona central no campo caracterizado por menores teores de K. Muito provavelmente, o K é semelhante aos atributos anteriores.




Figura 34. Interpolação por cokrigagem do K no solo cultivado com cana-de-açúcar.

O mapa da distribuição espacial do Mg (Figura 35) mostra que os valores mais elevados estão concentradas na região central, o que é esperado devido à associação com CTC, Mg e Ca.




Figura 35. Interpolação por cokrigagem do Mg no solo cultivado com cana-de-açúcar.

O mapa da variabilidade espacial da MO (Figura 36) mostra que existe uma tendência de decréscimo dos valores de leste para oeste e uma ampla área central com valores menores. Nessa área os resíduos da cultura foram mantidos na superfície, como consequência, a MO, provavelmente, sofreu maior decomposição na área central.




Figura 36. Interpolação por cokrigagem do MO no solo cultivado com cana-de-açúcar.

Distribuição espacial do P segundo a Figura 37 mostra uma variabilidade mais irregular, existe na área central uma faixa com valores menores, enquanto que as áreas leste e oeste apresentam valores maiores.




Figura 37. Interpolação por cokrigagem do P no solo cultivado com cana-de-açúcar.

Mapa da distribuição espacial do S (Figura 38) mostra gradiente espacial distinto, aumentando a partir do leste para oeste do campo e uma área restrita com valores maiores na fronteira sul.




Figura 38. Interpolação por cokrigagem do S no solo cultivado com cana-de-açúcar.

O mapa da variabilidade da Argila (Figura 39) mostra uma ampla zona central e a borda oeste do campo caracterizada por teores maiores de argila.




Figura 39. Interpolação por cokrigagem da argila no solo cultivado com cana-de-açúcar.

O mapa da distribuição espacial do Silte (Figura 40) mostra-se muito semelhante, mas significativamente menores do que os da Argila.




Figura 40. Interpolação por cokrigagem do silte do solo cultivado com cana-de-açúcar.

O mapa da variabilidade espacial do pH (Figura 41) mostra-se com variabilidade irregular, no entanto, é possível delimitar uma faixa larga atravessando a região mediana de todo o campo caracterizada por valores maiores de pH.




Figura 41. Interpolação por cokrigagem do pH no solo cultivado com cana-de-açúcar.

Resumindo, a parte oeste do campo pode ser caracterizada por variabilidade espacial de valores maiores para a maior parte das variáveis (Ca, CE, CC, MO, S, argila e silte).

6.1.5 Análise Regionalizada Fatorial

A fim de sintetizar as relações espaciais multivariadas e identificar um número restrito de zonas a serem submetidas à diferentes formas de manejo, a análise de cokrigagem fatorial foi realizada para mapear os fatores regionalizados significativos (Tabela 8). Deve-se ressaltar que a variabilidade em micro-escala foi afetada pelos erros de medição (efeito pepita) e, por isso, foi omitido na Análise Regionalizada Fatorial.

Na análise foram mantidos apenas os vetores próprios “autovetores” correspondentes aos valores superiores a um (1), devido à padronização das variáveis à variância um.

A estrutura dos fatores regionalizados na escala de 380 m, com a variância explicada (%) para cada fator (Tabela 8). A variação acumulada de aproximadamente (74%) a esta escala foi explicada pelos fatores regionalizados em conjunto, com o primeiro (47,61%) e segundo (26,33%), assumindo como suficiente para caracterizar o componente estrutural de variação no campo.

Tabela 8. Decomposição das variáveis Gauss do solo a partir dos fatores regionalizados; relataram os autovalores diferentes de zero e as percentagens da variância explicada para cada escala espacial

	*gDs	gCTC	gCa	gCE	gCC	gK	gMg	gMO	gP	gS	gsilte	gargila	gpH	Autoval.	Var. %
S1=efeito pepita															
Fator 1	0,3354	-0,4311	-0,1992	0,1048	-0,4632	-0,3219	-0,3115	-0,1925	-0,1346	0,121	-0,1772	-0,364	0,0459	2,1365	29,33
Fator 2	-0,1599	-0,1979	0,3532	0,2304	-0,0183	0,0966	0,3786	-0,1881	0,2197	-0,1777	-0,294	-0,2502	0,5833	1,6340	22,43
Fator 3	-0,1728	-0,0663	0,1704	-0,5468	0,0514	-0,6023	-0,0672	0,2960	-0,0391	-0,3952	-0,0583	-0,0348	0,1334	1,2339	16,94
Fator 4	-0,6177	-0,0440	-0,0374	0,0367	0,0542	-0,2063	0,0911	-0,4553	-0,5513	0,2077	0,0019	0,056	-0,0503	0,6760	9,28
S2=modelo esférico na escala= 380.00 m															
Fator 1	0,0615	-0,4123	-0,3717	-0,2975	-0,2004	-0,1008	-0,2749	-0,2819	-0,0986	-0,2765	-0,4132	-0,3702	0,0159	3,2486	47,61
Fator 2	0,1578	0,1371	0,4149	-0,3472	-0,2259	-0,2039	0,3855	-0,2957	0,2483	-0,4022	0,0838	0,0074	0,3232	1,7963	26,33

*g = variáveis padronizadas em Gauss.

Os valores de carregamento indicam que o primeiro fator (F1) foi influenciado, principalmente, pelas variáveis CTC, Ca, silte e argila que contribuem negativamente. É consistente com a análise anterior, porque essas variáveis apresentaram estruturas espaciais semelhantes (Figuras 30, 31, 39 e 40). O segundo fator (F2) foi influenciado, principalmente, por variáveis de Ca, Mg e pH que contribuem positivamente e estas variáveis estão mais relacionadas com a geoquímica do solo. Isto significa, principalmente, que o primeiro fator está indiretamente relacionado à textura do solo, enquanto que o segundo fator está diretamente relacionada fertilidade química.

Na Figura 42, o mapa de F1 foi dividido em três classes de isofrequência (alta, média e baixa) que podem ser interpretadas como zonas que caracterizam textura homogênea.




Figura 42. Mapa em três zonas de manejo (ZMs) para o primeiro fator do modelo de solo.

O mapa de F1 delimitou uma ampla área central onde a variação espacial é provavelmente dominada por alguns fatores inerentes à gênese do solo, entre os quais os componentes texturais que detêm uma posição importante porque influenciam o fluxo vertical, lateral e lixiviação de cátions. Além disso, as partículas de argila têm carga líquida negativa, que é neutralizada por cations adsorvidos, cuja quantidade total é expressa pela CTC do solo.

No mapa de F2 (Figura 43) mostra uma grande área central, caracterizada por um maior concentração de elementos químicos (Mg, Ca) determinando a fertilidade do solo da área.




Figura 43. Mapa representado em três zonas de manejo (ZMs) para o segundo fator do modelo de solo.

Do ponto de vista agrônômico, a zona central pode ser diferenciada em comparação com ao manejo das demais áreas mais periféricas, porque apresenta uma textura mais fina e mais rica de macronutrientes. No entanto, a área central foi caracterizada por menores teores de MO, por isso, pode-se dar uma atenção maior no sentido de elevar os níveis de MO com adição de material orgânico nesta região.

6.2 Delimitação das zonas de manejo (ZMs) utilizando dados da radiância espectral do Landsat-8

6.2.1 Análise descritiva dos dados

Foi evidente que as distribuições das bandas espectrais mostraram-se com tendência enviesada, com desvios sensíveis à distribuição normal, com exceção da banda 5 (Tabela 9).

Uma dificuldade na aplicação de uma abordagem multivariada ocorre quando as variáveis são diferentes em dimensão e variância. A modelagem do variograma torna-se complexa pela presença de *outliers* na distribuição dos dados. Neste caso, a melhor solução é a normalização dos dados através de Modelagem Anamorfose Gaussiana. Portanto, os dados foram transformados por Anamorfose Gaussiana e padronizados para média zero e variância um.

Tabela 9. Estatística descritiva das bandas espectrais da imagem do Landsat-8

Variáveis	N*	Min	Max	Média	Desvio Padrão	Coef. de Assimetria	Coef. de Curtose
Banda 1	728	0,1108	0,1523	0,1146	0,0025	5,7487	7,3348
Banda 2	728	0,0924	0,1118	0,0964	0,0027	1,8135	7,0055
Banda 3	728	0,0866	0,1118	0,0934	0,0041	2,2231	9,9194
Banda 4	728	0,0582	0,1626	0,0751	0,0133	1,8467	7,9801
Banda 5	728	0,2657	0,4396	0,3628	0,0337	-0,1915	2,4682
Banda 6	728	0,1487	0,2660	0,1770	0,0189	1,0552	3,9983
Banda 7	728	0,0614	0,2141	0,0914	0,0234	1,2224	4,6586
Banda 10	728	9,9933	10,9682	10,3100	0,1741	0,7618	2,8762
Banda 11	728	9,2531	9,9158	9,4665	0,1159	0,8057	3,1708

*Número de pixels

A matriz dos coeficientes de correlação de Pearson para todas as bandas utilizadas no modelo (Tabela 10) mostrou que todas as bandas, com exceção das bandas 10 e 11 estão fortemente correlacionadas entre si, com nível de correlação de 0,99.

Tabela 10. Matriz de correlação de Pearson para as bandas espectrais e termiais da imagem do Landsat-8

Variáveis	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7	Banda 10	Banda 11
Banda 1	1,00	0,74	0,71	0,71	-0,52	0,68	0,69	-0,11	-0,11
Banda 2		1,00	0,95	0,96	-0,73	0,93	0,94	-0,09	-0,09
Banda 3			1,00	0,91	-0,56	0,87	0,86	-0,05	-0,05
Banda 4				1,00	-0,81	0,92	0,97	-0,12	-0,12
Banda 5					1,00	-0,75	-0,84	0,12	0,12
Banda 6						1,00	0,97	-0,06	-0,06
Banda 7							1,00	-0,10	-0,10
Banda 10								1,00	0,99
Banda 11									1,00

Todos os coeficientes de correlação > 0,13 são significativos para p 0,05 de probabilidade.

6.2.2 Análise de correionalização

A geoestatística multivariada foi aplicada para os dados de sensoriamento remoto, significando que foi assumido que há relação entre as assinaturas espectrais da cultura e suas propriedades bioquímicas, biofísicas e culturais da cana-de-açúcar. Ferramentas multivariadas extraem e evidenciam as correlações em um modelo, o qual é chamado Modelo Linear de Correionalização.

Determinar as principais causas de variação espacial na reflectância espectral da vegetação é uma tarefa complexa, porque a cultura é afetada por vários fatores, tais como: condições climáticas, propriedades do solo, índice de área foliar (cobertura vegetal por unidade de área), fase de crescimento (fase de desenvolvimento da cultura), a biomassa por unidade de área (densidade de massa verde), as propriedades da folha (forma, posição, teor de água, pigmentação, estrutura interna), geometria temporal do satélite (iluminação, imagem, sol/superfície/satélite), etc.

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

Embora na geoestatística não é possível escolher o número de estruturas básicas em um teste estatístico, a inspeção visual dos variogramas (Figura 39) sugeriram a presença de três componentes básicos, o que corresponde às diferentes escalas espaciais (efeito pepita, escala curta = 350 m modelo esférico e escala longa = 750 m modelo esférico).

Na primeira estrutura foi observado efeito pepita, compreendendo à variabilidade não conhecida durante a aquisição da imagem e outros erro de medição. Esta estrutura foi detectada em todos os variogramas e teve um peso igual para todas as bandas. A segunda estrutura refletiu um processo espacial transitivo na escala média, aproximadamente à distância de 350 m de alcance e foi relevante para as bandas termais 10 e 11. A terceira estrutura representou um modelo transitivo com uma gama relativamente grande de variação do alcance de 350 a 750 m. Esta estrutura foi predominante para as bandas espectrais 1, 2, 3, 4, 5, 6 e 7.

Os variogramas diretos e cruzados foram modelados com a soma de três estruturas espaciais, incluindo: um efeito pepita, um modelo esférico com alcance igual a 350 m e um modelo esférico com alcance de 750 m. O ajuste do MLC foi

verificado através do teste de validação cruzada e duas estatísticas de erros médios foram calculadas para a média e a variância do erro.

As Figuras 44, 45 e 46 ilustram os variogramas experimentais simples e cruzados (pontos experimentais), juntamente com o modelo linear de correionalização (modelo teórico). A maioria dos variogramas diretos mostrou-se bem estruturado, com um mesmo componente geral de efeito pepita. Nos variogramas cruzados das bandas, apenas as bandas espectrais foram correlacionadas espacialmente, enquanto que a correlação espacial foi nula entre as bandas termais e espectrais.




Figura 44. Variogramas diretos e cruzados das bandas espectrais e termais da imagem do Landsat-8.




Figura 45. Variogramas diretos e cruzados das bandas espectrais e termais da imagem do Landsat-8 (continuação).




Figura 46. Variogramas diretos e cruzados das bandas espectrais e termais da imagem do Landsat-8.

Para os dados multivariados espaciais observou-se que, além da correlação espacial entre as observações também existe uma relação forte entre diversas bandas. Portanto, os coeficientes de correlação dependentes de cada escala estrutural foram estimados, através da filtragem do efeito pepita. Desta maneira, os componentes revelaram correlações espaciais mais fortes ou mais fracas para muitos pares de variáveis em comparação com os coeficientes de Person.

Coeficiente alto de correlação foi observado na escala curta (Tabela 11) para a maioria dos pares de bandas, com a exceção dos pares de bandas 10-05 e 11-05. Na maioria dos pares esses coeficientes foram maiores do que os coeficientes de correlação

de Pearson. 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 às propriedades locais do solo e das culturas (índice de área foliar, fase de crescimento, a densidade de massa verde, teor de água folha, etc).

Na escala longa (Tabela 12), os coeficientes de correlação entre as bandas termais (10 e 11) e as outras bandas, diminuíram em comparação com os de escala curta. No entanto, ocorreu uma alta correlação entre as bandas de 03-10 (0,90) e bandas de 11-3 (0,89), porque as bandas termais estão relacionadas com as alterações das temperaturas emitidas da superfície. Já, a banda 3 (verde) mostrou-se sensível à concentração de clorofila através de uma gama mais ampla do conteúdo de clorofila. Banda verde é sensível à biomassa de uma comunidade de plantas e, portanto, a quantidade de clorofila por unidade de área. O valor dessa biomassa pode ser diretamente relacionado ao índice de área foliar e produtividade das culturas. É importante lembrar que a clorofila seletiva absorve energia radiante e, posteriormente, converte e armazena as substâncias orgânicas através da fotossíntese, portanto, a banda do verde pode ser utilizada no monitoramento da cultura.

Alguns coeficientes de correlação mudaram seu sinal após a filtragem do efeito pepita na estrutura de curta escala. Por exemplo, as elevadas correlações negativas das bandas de 1-10, 1-11, 2-10, 2-11, 3-10, 6-11 e 7-10 na curta escala tornaram-se positiva e menor na longa escala. Estas relações estruturais sugerem que os processos que afetam as bandas termais de curta escala podem ser diferentes no tipo e intensidade daqueles que influenciam as mesmas bandas em escala longa.

Todos os resultados acima sugerem que diferentes processos agem sobre a área de estudo em diferentes escalas espaciais.

Tabela 11. Coeficientes estruturais na escala curta para as bandas espectrais e termiais da imagem Landsat-8

Variáveis	banda 1	banda 10	banda 11	banda 2	banda 3	banda 4	banda 5	banda 6	banda 7
banda 1	1								
banda 10	-0,9790	1							
banda 11	-0,9844	0,9947	1						
banda 2	0,9869	-0,9347	-0,9442	1					
banda 3	0,9835	-0,9882	-0,9930	0,9501	1				
banda 4	0,9144	-0,8235	-0,8429	0,9614	0,8749	1			
banda 5	-0,7105	0,5846	0,6186	-0,7907	-0,6829	-0,9275	1		
banda 6	0,9762	-0,9904	-0,9936	0,9355	0,9989	0,8514	-0,6521	1	
banda 7	0,9498	-0,8826	-0,9004	0,9759	0,9296	0,9908	-0,8947	0,9117	1

Tabela 12. Coeficientes estruturais na escala longa para as bandas espectrais e termiais da imagem Landsat-8

Variáveis	banda 1	banda 10	banda 11	banda 2	banda 3	banda 4	banda 5	banda 6	banda 7
banda 1	1								
banda 10	0,5481	1							
banda 11	0,5343	0,9993	1						
banda 2	0,9805	0,5489	0,5401	1					
banda 3	0,8163	0,9019	0,8973	0,8406	1				
banda 4	0,9556	0,3583	0,3491	0,9474	0,6628	1			
banda 5	-0,8301	-0,0117	-0,0006	-0,8399	-0,4146	-0,9167	1		
banda 6	0,9685	0,5673	0,5615	0,9753	0,8148	0,9689	-0,8099	1	
banda 7	0,9559	0,3836	0,3764	0,9561	0,6875	0,9964	-0,9084	0,9758	1

6.2.3 Validação cruzada para o modelo das variáveis espectrais

Da Figura 47 a 55 apresentam a validação cruzada da análise variográfica das bandas espectrais.

Houve uma forte correlação entre os valores reais e estimados da banda espectral 1 com valor de r de 0,833 (Figura 47). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados não apresentou correlação significativa. O histograma dos erros padronizados da estimativa é suficientemente simétrico com alguns valores discrepantes. A média do erro padronizado é próxima de zero (0,005), o que significa que o modelo não é tendencioso e a variância de erro padronizado é próxima de um (0,880), o que significa que a estimação do modelo é precisa.




Figura 47. Os resultados da validação cruzada para banda espectral 1 do Landsat-8.

Para a banda espectral 2, há uma forte correlação entre os valores verdadeiros e estimados (Figura 48) com um valor de r de 0,892. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com pequeno valor de r . O histograma dos erros de estimativa padronizado tem poucos pontos fora do intervalo de -2,5 a 2,5. A média do erro padronizado é próxima de zero (-0,002), o que significa que o modelo não é tendencioso e a variância de erro padronizado é próxima de um (0,769), o que significa que o modelo é bom para estimativas teóricas.




Figura 48. Os resultados da validação cruzada para banda espectral 2 do Landsat-8.

Houve uma alta correlação entre os valores reais e estimados da banda espectral 3 com valor de r de 0,869 (Figura 49). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com relação ao eixo horizontal, com um baixo valor de r . O histograma dos erros da estimativa padronizado tem alguns valores discrepantes encontrados fora do intervalo entre -2,5 e 2,5. A média do erro padronizado é próxima de zero (-0,003), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,770), o que significa que o modelo da estimativa é acurado.




Figura 49. Os resultados da validação cruzada para banda espectral 3 do Landsat-8.

Para a banda espectral 4, há uma forte correlação (Figura 50) entre os valores verdadeiros e estimados com um valor de r de 0,873. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com um baixo valor de r . O histograma dos erros da estimativa padronizado tem alguns pontos de valores menores do que 2,5 e um maior que 2,5. A média do erro padronizado é próxima de zero (-0,002), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,733), o que significa que o modelo é aceitável.




Figura 50. Os resultados da validação cruzada para banda espectral 4 do Landsat-8.

Uma correlação muito forte entre os valores verdadeiros e estimados para a banda espectral 5 é ilustrado na (Figura 51), com valor de r de 0,912. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com um baixo valor de r . O histograma dos erros da estimativa padronizado é simétrico com poucos pontos maiores do que 2,5. A média do erro padronizado é próxima de zero (0,001), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,638), o que significa que a estimação do modelo é precisa.




Figura 51. Os resultados da validação cruzada para banda espectral 5 do Landsat-8.

Houve correlação muito forte entre os valores verdadeiros e estimados da banda espectral 6 com o valor de r de 0,904 (Figura 52). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é simétrico com valor de r de -0,133. O histograma dos erros da estimativa padronizada tem alguns pontos com valores menores do que -2,5 ou maior do que 2,5. A média do erro padronizado é próxima de zero (-0,001), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,698), o que significa que a estimação do modelo é precisa.




Figura 52. Os resultados da validação cruzada para banda espectral 6 do Landsat-8.

Houve correlação muito forte entre os valores verdadeiros e estimados da banda espectral 7 com valor de r de 0,940 (Figura 53). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece simétrico com valor de r de -0,148. O histograma dos erros da estimativa padronizada tem alguns valores inferiores a -2,5 e um valor maior do que 2,5. A média do erro padronizado é próxima de zero (0,013), o que significa que o modelo não é tendencioso e variância do erro padronizado é próxima de um (1,057).




Figura 53. Os resultados da validação cruzada para banda espectral 7 do Landsat-8.

Uma correlação muito forte entre os valores verdadeiros e estimados da banda termal 10 foi encontrada com valor de r de 0,958 (Figura 54). O diagrama de dispersão da estimativa dos erros padronizados versus os valores estimados parece suficientemente simétrico com valor de r de -0,085. O histograma dos erros da

estimativa padronizado tem poucos valores encontrados fora do intervalo de -2,5 a 2,5. A média do erro padronizado é próxima de zero (0,006), o que significa que o modelo não é tendencioso e a variância do erro padronizado (0,760), o que significa que a estimação do modelo é acurada.




Figura 54. Os resultados da validação cruzada para banda termal 10.

Para a banda termal 11, existe uma elevada correlação (Figura 55) entre os valores reais e estimados com um valor de r de 0,952. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com valor de r de -0,088. O histograma dos erros da estimativa padronizado apresentam alguns pontos encontrados fora do intervalo entre -2,5 e 2,5. A média do erro padronizado é próxima de zero (0,006), o que significa que o modelo não é tendencioso e a

variância do erro padronizado é próxima de um (0,600), o que significa que o modelo é bom para as estimativas teóricas.




Figura 55. Os resultados da validação cruzada para banda termal 11 do Landsat-8.

6.2.4 Análise Regionalizada Fatorial

De modo a sintetizar as relações multivariadas espaciais e identificar números restritos de zonas a ser submetida ao manejo diferenciado, a análise de cokrigagem fatorial foi realizada para mapear os fatores regionalizados (Tabela 13). A soma dos autovalores significativos em cada escala espacial foi pequena em micro-escala em comparação com os que estão em escalas mais longas (obtendo uma estimativa da variação na escala correspondente). Tendo em conta que a variabilidade relacionada ao efeito pepita é amplamente afetada por erros de medição, foi omitida da discussão.

Na análise fatorial apenas os autovetores correspondentes aos valores superiores a um foram mantidos devido à padronização das variáveis à variância um.

A estrutura dos fatores regionalizados na escala curta de 350 m, com a variância explicada (%) para cada fator (Tabela 13). A variação na escala curta foi explicada apenas pelo primeiro fator regionalizado com 92,00%. A variação acumulada em escala longa foi explicada pelo primeiro (77,00%) e segundo (21,63%) 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 2, 3 e 4 e negativamente pelas bandas termais 10 e 11. Na escala longa, o primeiro fator é influenciado positivamente pelas bandas espectrais 2, 6 e 7 com maior peso e o segundo fator negativamente, pelas bandas termais 10 e 11, com maior peso.

Isto significa que o primeiro fator na escala curta está relacionado diretamente com a biomassa (densidade de massa verde) e o teor de clorofila e indiretamente com a temperatura de superfície. Isso porque as folhas verdes da vegetação exibem muito baixa reflectância e transmitância na região visível do espectro (isto é, 400 a 700 nm) devido à forte absorvância pelos pigmentos fotossintéticos da planta e seus acessórios (CHAPPELLE et al., 1992).

O primeiro e segundo fator na escala longa está relacionado diretamente com conteúdo de água na planta e, indiretamente com a temperatura da superfície. Dados termais em conjugação com as bandas do visível e infravermelho próximo (NIR), correspondendo às bandas 6 e 7, tem permitido a exclusão do material não-folha na estimativa da temperatura do dossel e a possibilidade de seleccionar partes específicas do dossel para a estimativa de estresse-hídrico (JONES, 2004) .

A análise conjunta de dados multivariados como: bandas termais para verificar remotamente a temperatura do dossel; banda 6 e banda 7 para caracterizar 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). No entanto, o conhecimento destas relações é necessário, para acessar e traduzir os dados com precisão em variabilidade espacial e ter utilidade em aplicações na Agricultura de Precisão.

Tabela 13. Decomposição em fatores regionalizados das bandas gaussianas e também os autovalores diferentes de zero e as porcentagens da variância explicada para cada escala espacial

S1=efeito pepita	gbanda 1	gbanda 2	gbanda 3	gbanda 4	gbanda 5	gbanda 6	gbanda 7	gbanda 10	gbanda 11	Aut. valores	Variância %
Fator 1	0,3968	0,3607	0,3702	0,4588	-0,2818	0,3581	0,3906	0,0477	0,0485	1,0346	67,97
Fator 2	0,3729	0,1872	0,5075	-0,1795	0,5792	-0,0918	-0,258	-0,2451	-0,2562	0,2190	14,39
Fator 3	-0,5531	0,0203	0,0145	0,0115	0,2331	0,5515	0,2677	-0,358	-0,3674	0,1247	8,19
Fator 4	-0,6235	0,3329	0,5515	0,0694	-0,1082	-0,2531	-0,1749	0,1794	0,2302	0,0787	5,17
Fator 5	0,0111	-0,8297	0,528	0,0047	-0,1337	0,0949	0,0582	0,047	0,0126	0,0322	2,12
Fator 6	0,0071	-0,0534	-0,0141	0,0673	0,1051	-0,0636	0,1067	-0,6852	0,7046	0,0170	1,12
Fator 7	-0,0829	-0,1187	-0,0548	0,4006	0,4767	-0,491	0,5567	0,1782	-0,074	0,0119	0,78
Fator 8	-0,0402	-0,1344	-0,1378	0,7184	0,2272	0,2081	-0,5876	0,0544	0,0456	0,0041	0,27
S2=Esférico-escala= 350.00 m											
Fator 1	0,2980	0,3141	0,3177	0,3180	-0,2191	0,2698	0,2909	-0,4475	-0,4526	3,1817	92,04
Fator 2	-0,0493	0,1151	-0,1274	0,4380	-0,6687	-0,1500	0,2720	0,3711	0,3080	0,2529	7,32
Fator 3	-0,3087	-0,5911	0,3670	-0,2748	-0,4298	0,3836	0,0492	0,0218	-0,1020	0,0191	0,55
Fator 4	0,0947	0,0680	-0,0586	-0,1137	-0,0140	-0,0876	-0,0210	0,6613	-0,7242	0,0030	0,09
S3=Esférico-escala= 750.00 m											
Fator 1	0,3614	0,3882	0,2837	0,3561	-0,3599	0,3809	0,3880	0,2100	0,2052	4,8922	77,09
Fator 2	0,0252	0,0236	-0,3239	0,1763	-0,4730	0,0111	0,1696	-0,5527	-0,5521	1,3724	21,63
Fator 3	-0,1484	-0,3915	-0,4736	0,3894	0,3688	0,3826	0,3847	0,0751	0,1133	0,0601	0,95
Fator 4	0,8484	-0,2548	-0,2310	0,1376	0,0918	-0,3038	-0,1511	0,1293	-0,0534	0,0191	0,3
Fator 5	-0,0748	0,2152	-0,1686	0,4159	-0,0135	0,3585	-0,7785	0,0850	-0,0680	0,0021	0,03

Na Figura 56, o mapa de F1 na escala curta foi dividido em três classes de mesma frequência (alta, média e baixa) que podem ser caracterizadas como zonas homogêneas em biomassa verde da cultura e teor de clorofila.

Para esta finalidade, os sinais de reflectância, em comprimentos específicos de onda na faixa do visível do espectro, são funcionais como indicadores de cobertura do dossel e teor de clorofila. A propriedade bioquímica mais comumente usada é o teor de clorofila. Ele reflete a condição geral da cultura em biomassa verde, uma vez que a clorofila é a responsável pela produção e produtividade da cultura; estas características foram delineadas na região central do campo definida pelas classes de maior reflectância, refletidas por plantas com maior vigor (Figura 56).

Perdas no conteúdo da clorofila podem indicar disponibilidade limitada de elementos importantes, entre uma ampla possibilidade de opções ou outros estresses bióticos ou abióticos. No entanto, a detecção da deficiência de clorofila não é um indicador de que a causa da deficiência foi induzida. O estado da saúde da cultura pode ser indicado por temperatura da folha. Métodos de detecção na região infravermelha termal podem ser relatados como capazes de prever deficiência de clorofila nas folhas e caules, medindo a temperatura da folha.

Estes resultados dão a ideia de que as observações de sensoriamento remoto óptico podem ser usadas para monitorar a atividade fotossintética da cultura e, indiretamente, para estimar o acúmulo de biomassa seca.




Figura 56. Mapa em três zonas de manejo (ZMs), de acordo com o primeiro fator em curta escala (350 m), para o modelo espectral.

As Figuras 57 e 58 referentes aos mapas de F1 e F2, em longa escala, foram divididas em três classes de mesma frequência (alta, média e baixa) que podem ser interpretadas como zonas homogêneas em conteúdo de água na cultura pela banda 2 e pelas bandas 6 e 7 e temperatura da superfície pelas bandas termais 10 e 11.

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 aos diferentes teores de água do dossel. No mapa da Figura 57 foi observado polígonos com maiores teores de água na região central, onde a vegetação encontra-se mais exuberante com maior biomassa. Algumas áreas podem apresentar efeitos de borda, no qual a cultura fica suscetível à influência externa, como por exemplo, o stress hídrico que influencia negativamente o crescimento da cultura.

O monitoramento do conteúdo hídrico da vegetação na banda 2 de azul e bandas 6 e 7 de ondas curtas no infravermelho próximo é de grande interesse em agricultura de precisão, o qual se baseia no período de irrigação para garantir que a cultura não seja influenciada com estresse hídrico e tenha rendimento máximo em condições adequadas de água.

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 transpiração, pode ser afetado pela temperatura da folha. Dados termais infravermelhos foram utilizados para delinear zonas caracterizadas com potencial ao estresse hídrico, na cultura da cana-de-açúcar, conforme mostra a Figura 58, definido pelos polígonos de baixa refletância. A região do infravermelho termal tem sido relatada como capaz de prever o potencial de água nas folhas e caule, medindo a temperatura das folhas (MOLLER et al., 2007).




Figura 57. Mapa em três zonas de manejo (ZMs), de acordo com o primeiro fator em longa escala (750 m) para o modelo espectral.




Figura 58. Mapa em três zonas de manejo (ZMs), de acordo com o segundo fator em longa escala (750 m) para o modelo espectral.

6.3 Delimitação das Zonas de Manejo (ZM_s) pela fusão de dados de solo e de sensoriamento remoto

6.3.1 Definição do conjunto de dados para o modelo fusionado

A Análise de Componentes Principais (ACP) permitiu associar variáveis de solo (0-20 cm e 20-40 cm) e bandas de reflectância, reduzindo assim a dimensionalidade do conjunto de dados. A rotação Varimax permitiu selecionar as variáveis que mais afetam a variabilidade espacial no campo.

As variáveis selecionadas foram: Ds (0,2-0,4 m), CTC (0-0,2 e 0,2-0,4 m), argila (0-0,2 e 0,2-0,4 m), CC (0-0,2 e 0,2-0,4 m), MO (0-0,2 e 0,2-0,4 m) e as bandas espectrais 3, 5, 6, 7 e bandas termais 10 e 11.

Os dados espectrais da banda 3 - verde, banda 5 - infravermelho próximo (NIR), banda 6 - SWIR 1, banda 7 - SWIR 2, banda 10 e da banda 11- infravermelho termal foram utilizadas como atributo secundário para criar o modelo de fusão.

6.3.2 Análise descritiva dos dados

As estatísticas descritivas para as quinze variáveis são apresentados na Tabela 14. A maioria das variáveis de solo mostraram completamente distribuições simétricas, e nos dados de reflectância apenas a banda 3 mostrou assimetria positiva, ou seja, a distribuição tem uma cauda á direita com valores acima da média. Algumas variáveis apresentaram valores de coeficiente de curtose maior que 3 como argila na profundidade 0-0,2 m, banda 3 e banda 7, então a distribuição em questão é leptocúrtica.

Consequentemente, todas as variáveis foram submetidas à Modelagem Anamorfose Gaussiana, ou seja, os dados brutos de cada variável foi definido em distribuição normal, em um conjunto com média zero e variância unitária. As expansões polinomiais de Hermite foram restringidas aos primeiros 100 elementos, em que a relação entre a variação dos valores transformados e a variância calculada, a partir dos dados, foi aproximadamente constante e igual a um (WACKERNAGEL, 2003).

Tabela 14. Estatística descritiva das variáveis do modelo fusionado

Variáveis	Min	Max	Média	Desvio Padrão	Coef. de Assimetria	Coef. de Curtose
Ds ^B	1,47	1,79	1,66	0,08	-0,43	2,58
Argila ^A	75,00	415,00	254,37	70,78	-0,03	3,20
Argila ^B	75,00	412,00	261,49	74,20	-0,11	2,55
CC ^A	0,19	0,33	0,26	0,03	0,17	2,53
CC ^B	0,18	0,32	0,25	0,03	0,11	2,89
CTC ^A	38,09	85,40	62,31	12,13	-0,09	1,94
CTC ^B	41,22	99,92	64,65	14,62	0,33	2,14
MO ^A	8,07	19,90	14,80	3,06	-0,42	2,15
MO ^B	7,55	22,04	14,26	3,41	0,30	2,69
banda 3	0,09	0,11	0,09	0,00	1,97	8,15
banda 5	0,29	0,44	0,36	0,03	0,06	2,62
banda 6	0,15	0,22	0,18	0,02	0,73	2,53
banda 7	0,06	0,15	0,09	0,02	0,93	3,23
banda 10	10,04	10,78	10,31	0,17	0,79	2,84
banda 11	9,28	9,77	9,47	0,11	0,78	2,91

^Aprofundidade (0-0,2 m) e ^Bprofundidade (0,2-0,4 m).

A correlação linear de Pearson entre as variáveis estudadas (Tabela 15) foram significativas, para todas as variáveis do solo coletadas em duas profundidades. Densidade do solo mostrou correlação negativa com a capacidade de troca catiônica, argila, capacidade de campo e matéria orgânica. As demais variáveis foram positivamente correlacionadas com coeficientes de médio a alto. As bandas espectrais 3, 6 e 7 apresentaram correlação positiva com argila, essa correlação justifica-se pela característica argilosa do solo, alta presença de conteúdo de água na fração argila. As bandas termais 10 e 11 foram positivamente correlacionadas com a densidade do solo e negativamente com a capacidade de campo e matéria orgânica.

Os principais constituintes dos solos que influenciam o comportamento espectral são a matéria orgânica, óxidos de ferro, minerais de argila, além da distribuição de tamanho de partículas e umidade.

Tabela 15. Matriz de correlação das variáveis do modelo de fusão

Variáveis	gDsB	gCTCA	gCTCB	gArgilaA	gArgilaB	gCCA	gCCB	gMOA	gMOB	gbanda3	gbanda5	gbanda6	gbanda7	gbanda10	gbanda11
gDsB	1														
gCTCA	-0,26	1													
gCTCB	-0,23	0,79	1												
gArgilaA	-0,42	0,78	0,73	1											
gArgilaB	-0,36	0,76	0,72	0,91	1										
gCCA	-0,39	0,48	0,4	0,56	0,48	1									
gCCB	-0,61	0,48	0,5	0,7	0,59	0,69	1								
gMOA	-0,47	0,54	0,52	0,57	0,46	0,36	0,55	1							
gMOB	-0,35	0,63	0,61	0,7	0,61	0,46	0,6	0,66	1						
gbanda 3	-0,09	0,18	0,13	0,24	0,3	0,1	0,1	-0,02	0,03	1					
gbanda 5	0,09	-0,05	-0,04	-0,23	-0,18	-0,08	-0,15	-0,3	-0,12	-0,53	1				
gbanda 6	-0,1	0,17	0,11	0,27	0,32	0,04	0,09	0,1	0,04	0,87	-0,79	1			
gbanda 7	-0,08	0,12	0,06	0,26	0,28	0,06	0,11	0,15	0,07	0,79	-0,9	0,96	1		
gbanda10	0,28	-0,08	-0,04	-0,18	-0,07	-0,3	-0,31	-0,31	-0,31	-0,04	0,15	-0,06	-0,11	1	
gbanda11	0,29	-0,09	-0,05	-0,2	-0,08	-0,31	-0,32	-0,33	-0,32	-0,03	0,16	-0,06	-0,11	0,99	1

^Aprofundidade (0-0,2 m) e ^Bprofundidade (0,2-0,4 m)

6.3.3 Análise de correionalização

Os variogramas experimentais direcional para todas as variáveis não apresentaram evidência de anisotropia, portanto, o Modelo Linear de Correionalização (MLC) isotrópico foi ajustado para todos os variogramas (diretos e cruzados). Os valores dos parâmetros dos variogramas experimentais isotrópicos para as variáveis foram: tamanho do passo (lag) 79 m e 7 número de passos (lag).

O MLC ajustado incluiu três estruturas básicas: efeito pepita, modelo esférico (de curta escala e alcance igual a 250 m) e um modelo esférico (de longa escala e alcance igual a 600 m).

Na primeira estrutura foi observado um efeito pepita, compreendendo a variação espacial não resolvida que ocorrem às distâncias menores do que a escala de amostragem ou erro de medição. Esta estrutura pode ser vista em todos os variogramas e foi mais predominante nas variáveis do solo do que das de reflectância.

A segunda estrutura refletiu um processo transitivo espacial na escala média, aproximadamente até uma distância de 250 m e foi relevante para CTC e argila nas duas profundidades e para MO em 0,2-0,4 m.

A terceira estrutura teve uma elevada contribuição para a variância e representou um processo transitivo espacial ao longo de um intervalo relativamente grande (até 600 m). Esta estrutura foi predominante para as bandas 6, 7, 10 e 11.

O bom ajuste do MLC foi verificado com o teste de validação cruzada, o qual produziu os valores da média do erro padronizado e a variância do erro padronizado próximo de zero e um, respectivamente, para qualquer variável transformada em Gauss.

As Figuras 59, 60 e 61 ilustram os variogramas experimentais simples e cruzados (ponto experimentais), juntamente com o modelo linear de correionalização (modelo teórico). A maioria dos variogramas diretos mostrou-se bem estruturado, com um efeito pepita baixo para os dados de reflectância e maior para as variáveis de solo, devido à diferença na resolução espacial dos dois tipos de observações.

Os variogramas cruzados das bandas espectrais e termiais foram espacialmente correlacionados com algumas das variáveis de solo, enquanto que a correlação espacial não foi significativa entre as bandas termiais e espectrais. O modelo

linear de correionalização depende de ambas autocorrelação entre as observações do mesmo tipo e relações espaciais entre variáveis diferentes.

Os variogramas cruzados mostram que a reflectância das bandas (6 e 7-SWIR) e banda (3-VIS) foram correlacionados positivamente com argila nas duas profundidades e a banda (5-NIR) foi negativamente correlacionada com a MO e argila na primeira camada. A utilização da reflectância espectral através do visível, infravermelho próximo e ondas curtas do infravermelho (VIS-NIR-SWIR) na região (350-2500 nm) poderá, então, ser utilizada como preditor das mesmas propriedades do solo na camada superficial (SUMMERS et al., 2011).

Os variogramas cruzados das bandas termais foram positivamente correlacionados com a densidade do solo e negativamente com matéria orgânica e capacidade de campo, nas duas profundidades. Estas correlações significativas entre bandas termais e atributos do solo apontam a vantagem da utilização de indicadores termais, que podem avaliar a variabilidade do estado hídrico do solo dentro do campo e adquiridos remotamente.




Figura 59. Variogramas diretos e cruzados das variáveis do modelo de fusão.




Figura 60. Variogramas diretos e cruzados das variáveis do modelo de fusão (Continuação).




Figura 61. Variogramas diretos e cruzados das variáveis do modelo de fusão.

6.3.4 Validação cruzada para o modelo fusionado

A qualidade do ajuste do modelo foi avaliada através da validação cruzada calculando a média do erro padronizado, o qual mede o grau de tendência, e deve ser o mais próximo de zero possível.

As bandas gaussianas 3, 5, 6, 7, 10 e 11 transformadas, em valores de reflectância, foram utilizadas como variável padrão (conhecida em cada nó da rede de interpolação) na cokrigagem multicolocada.

A baixa correlação entre os valores reais e estimados de Ds 0,2-0,4 m, utilizando o modelo de fusão (Figura 62), foi r de 0,394. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é simétrico com relação ao eixo horizontal, com um baixo valor de r . O histograma dos erros da estimativa padronizada apresenta alguns valores discrepantes encontrados fora do intervalo (-2,5; 2,5). A média do erro padronizado é próxima de zero (-0,006), o que significa que o modelo não é tendencioso e a variância de erro padronizado é próxima de um (1,24), dentro do intervalo de tolerância.




Figura 62. Validação cruzada para Ds 0,2-0,4 m.

Os resultados da validação cruzada para CTC 0-0,2 m (Figura 63) mostram uma correlação média entre os valores verdadeiros e estimados com coeficiente de correlação (r) de 0,592. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados não mostrou correlação significativa com valor de r de -0,090. O histograma dos erros da estimativa padronizada é simétrico sem outlier fora do intervalo (-2,5; 2,5). A média do erro padronizado é próxima de zero (-0,004), o que significa que o modelo não é tendencioso e a variância de erro normalizado é próxima de um (0,77), o que significa que o modelo é bom para estimativas.




Figura 63. Validação cruzada para CTC 0-0,2 m.

Os resultados da validação cruzada para CTC 0,2-0,4 m (Figura 64) mostra correlação média entre os valores verdadeiros e estimados com coeficiente de correlação (r) de 0,513. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor de r de 0,006. O histograma dos erros da estimativa padronizada é simétrico sem valores fora do intervalo (-2,5; 2,5). A média do erro padronizado é próxima de zero (-0,0043), o que significa que o modelo não é tendencioso e a variância do erro normalizado é próxima de um (0,96), o que significa que a estimativa do modelo é precisa.




Figura 64. Validação cruzada para CTC 0,2-0,4 m.

A correlação média entre os valores verdadeiros e estimados de argila 0-0,2 m, utilizando o modelo de fusão (Figura 65) foi encontrado com valor de r de 0,652. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor de r de -0,145. O histograma dos erros da estimativa padronizada é simétrico sem valores fora do intervalo (-2,5; 2,5). A média do erro padronizado é próxima de zero (-0,004), o que significa que o modelo não é tendencioso e a variância de erro padronizado é próxima de um (0,88), portanto a estimação do modelo pode ser assumida.




Figura 65. Validação cruzada para argila 0-0,2 m.

A correlação entre os valores reais e estimados da argila 0,2-0,4 m, utilizando o modelo de fusão (Figura 66) foi média segundo o valor r 0,624. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com valor baixo r de -0,064. O histograma dos erros da estimativa padronizada é simétrico sem valores fora do intervalo (-2,5; 2,5). A média do erro padronizado é próxima de zero (-0,003), o que significa que o modelo não é tendencioso e a variância do erro padronizado é próxima de um (0,90), portanto a estimação do modelo pode ser assumida.




Figura 66. Validação cruzada para argila 0,2-0,4 m.

Uma menor correlação entre os valores reais e estimados da CC 0-0,2 m, utilizando o modelo de fusão (Figura 67) foi encontrada com valor de r de 0,556. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com baixo valor de r . O histograma dos erros da estimativa padronizada não apresenta valores com *outliers*. A média do erro padronizado é próxima de zero (0,0187), o que significa que o modelo não é tendencioso e a variância de erro padronizado é (0,811), portanto, a estimativa do modelo pode ser assumida.




Figura 67. Validação cruzada para CC 0-0,2 m.

A baixa correlação entre os valores reais e estimados de capacidade de campo 0,2-0,4 m, utilizando o modelo de fusão (Figura 68) foi encontrada com valor de r de 0,496. O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados é suficientemente simétrico com baixo valor de r . O histograma dos erros da estimativa padronizada não apresenta valores *outliers*. A média do erro padronizado é próxima de zero (0,011), o que significa que o modelo não é tendencioso e a variância de erro padronizado está dentro do intervalo de tolerância próximo de um (0,89).




Figura 68. Validação cruzada para CC 0,2-0,4 m.

Houve uma média correlação entre os valores reais e estimados de MO 0-0,2 m com valor de r de 0,611 (Figura 69). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com baixo valor de r . O histograma dos erros da estimativa padronizada apresenta um outlier inferior -2.5. A média do erro padronizado é próxima de zero (-0,032), o que significa que o modelo não é tendencioso e a variância de erro padronizado está dentro do intervalo de tolerância (1,00).




Figura 69. Validação cruzada para MO 0-0,2 m.

Houve correlação intermediária entre os valores verdadeiros e estimados da matéria orgânica 0,2-0,4 m, com valor de r de 0,680 (Figura 70). O diagrama de dispersão dos erros padronizados da estimativa versus os valores estimados parece suficientemente simétrico com baixo valor de r de -0,118. O histograma dos erros da estimativa padronizada não apresenta outliers. A média do erro padronizado é próxima de zero (-0,018), o que significa que o modelo não é tendencioso e a variância de erro padronizado é próxima de um (0,80), o que significa que a estimação do modelo é precisa.




Figura 70. Validação cruzada para matéria orgânica 0,2-0,4 m.

6.3.5 Cokrigagem Multicolocada para as variáveis fusionadas

As Figuras 71 a 79 apresentam os mapas cokrigados multicolocados que foram estimados por meio do modelo de fusão. O mapa de Ds (Figura 71) pode-se observar que os maiores valores estão concentrados na região centro-sul e são similares ao modelo com apenas as variáveis de solo, apresentando semelhante comportamento espacial dos valores.




Figura 71. Mapa da Ds de 0,2-0,4 m interpolado pelo modelo de fusão.

Os mapas de CTC para ambas as profundidades (Figura 72 e 73) são similares, com os maiores valores em uma faixa média NW-SE, ao longo da borda sul.




Figura 72. Mapa da CTC de 0-0,2 m interpolado pelo modelo de fusão.




Figura 73. Mapa da CTC de 0,2-0,4 m interpolado pelo modelo de fusão.

Os mapas espaciais de argila em ambas as profundidades (Figura 74 e 75) reproduzem mais ou menos as principais estruturas espectrais observadas nos mapas de CTC.




Figura 74. Mapa da argila de 0-0,2 m interpolado pelo modelo de fusão.




Figura 75. Mapa da argila de 0,2-0,4 m interpolado pelo modelo de fusão.

Os mapas da variabilidade espacial da capacidade de campo, para ambas as profundidades (Figura 76 e 77), de forma diferente do que as variáveis espacializadas anteriormente, mostram uma grande área central, caracterizada por os valores mais baixos.




Figura 76. Mapa da CC de 0-0,2 m interpolado pelo modelo de fusão.




Figura 77. Mapa da CC de 0,2-0,4 m interpolado pelo modelo de fusão.

Os mapas das distribuições espaciais da MO, nas duas profundidades (Figura 78 e 79), são semelhantes aos mapas de CC, com baixos valores no centro da área. Pode-se dizer que o conteúdo de MO afeta significativamente as propriedades hidráulicas do solo. Como os resíduos da cultura foram mantidos em superfície do terreno, a decomposição do material orgânico ocorreu de desuniformemente, com maior intensidade no centro do campo.




Figura 78. Mapa da MO de 0-0,2 m interpolado pelo modelo de fusão.




Figura 79. Mapa da MO de 0,2-0,4 m interpolado pelo modelo de fusão.

Em uma inspeção visual dos mapas de solos obtidos com o modelo de fusão são similares aos calculados a partir do modelo do solo, com um aumento da variabilidade em escala curta, devido à introdução dos dados em escala fina de reflectância do Landsat 8.

Resumindo, pode-se deduzir que esta área é caracterizada por uma grande área central com textura mais fina apresentando maiores valores de CTC, médios valores de Ds e menores valores de MO e CC. Portanto, o campo pode ser manejado com a deposição e a manutenção de palhada da cana sobre a superfície do solo, na parte central, o que iria melhorar também as propriedades de retenção de água e contribuindo com a conservação.

6.3.6 Análise Regionalizada Fatorial

Para decompor a variação multivariada do campo, em unidades de manejo representativas, foi aplicada a análise de cokrigagem fatorial multicolocada apenas aos autovetores com autovalores maiores que um. Os fatores foram analisados em sua respectiva escala espacial (Tabelas 16 e 17). Os autovetores associados ao efeito pepita foram omitidos porque são afetados por erros experimentais.

O primeiro fator em escala curta (250 m) e os dois primeiros fatores em escala longa (600 m), explicaram 86,28%, 51,15% e 41,31% da variação nas escalas espaciais correspondentes, respectivamente. Os principais coeficientes de carga para o primeiro fator regionalizado a 250 m de alcance foram as variáveis CTC, argila e MO, que pesaram negativamente, ou seja, são variáveis que indiretamente indicam a eficácia da fertilidade solo, principalmente nas camadas superficiais e seriam atributos de interesse na definição de zonas de manejo homogêneas.

A banda de 5 (NIR) pesou primeiramente positivamente nos coeficientes do primeiro fator regionalizado em longo alcance (600 m) e a banda 7 (SWIR 2) pesou negativamente. A relação negativa entre as duas bandas podem ser explicados com base em diferentes processos da cultura, refletido nas bandas. A reflectância na banda 5 está relacionada com a biomassa da planta, enquanto que a reflectância da banda 7, corresponde, geralmente, a absorção da água em tecidos das plantas. Portanto, quanto maior biomassa vegetal, maior a absorção de radiação e, então, menor será a reflectância.

Um método de estimativa do teor de água da planta é a utilização das bandas espectrais nas faixas de ondas curtas do infravermelho (SWIR) (1300-2500 nm). Usando dados de imagem de satélite, verificou-se que os índices de vegetação (IV) com base em NIR e SWIR são melhores correlacionados do que os IVs que utilizam bandas do visível e NIR, ao recuperar informações do conteúdo de água na folha (CECCATO et al, 2001; SIMS; GAMON, 2002; CHEN et al., 2005). Assim, tendo em conta do que foi considerado anteriormente, o fator regionalizado pode ser utilizado como um indicador de biomassa e conteúdo de água.

Tabela 16. Fatores regionalizados em escala curta (250 m) fator correspondente ao valor próprio superior a um

S2=modelo esférico-escala=250	gDs_ ^b	gCTC_ ^a	gCTC_ ^b	gargila_ ^a	gargila_ ^b	gCC_ ^a	gCC_ ^b	gMO_ ^a	gMO_ ^b	gbanda10	gbanda11	gbanda3	gbanda5	gbanda6	gbanda7
Fator 1	0,2041	-0,3893	-0,3238	-0,3656	-0,3943	-	-0,2309	-0,2461	-0,3847	0,1227	0,1197	-0,1962	0,0196	-0,1364	-0,0985
Fator 2	-0,3787	-0,2172	-0,1409	-0,0769	-0,0565	0,087	0,2073	-0,6489	0,0954	-0,2717	-0,2972	0,2142	0,0849	0,2456	0,1555
Fator 3	-0,1783	-0,1001	0,3463	-0,3085	-0,5302	0,1393	0,211	0,0424	0,4957	0,2059	0,2262	0,08	-0,0617	-0,1279	-0,1742
Fator 4	0,0318	-0,0354	-0,0161	-0,173	0,1693	-	0,059	0,0106	0,0281	-0,6756	0,6173	0,0048	-0,1008	0,1641	-0,2345
Auto. valores	Variância %														
3.5215	86,28														
0.3199	7,84														
0.2385	5,84														
0.0015	0,04														

Tabela 17. Fatores regionalizados em escala longa (600 m) fator correspondente ao valor próprio superior a um

S3=modelo esférico-escala=600	gDs_ ^b	gCTC_ ^a	gCTC_ ^b	gargila_ ^a	gargila_ ^b	gCC_ ^a	gCC_ ^b	gMO_ ^a	gMO_ ^b	gbanda10	gbanda11	gbanda3	gbanda5	gbanda6	gbanda7
Factor 1	0,0963	-0,005	0,0019	-0,0859	0,0063	-0,1625	-0,1814	-0,2174	-0,0798	0,3632	0,3690	-0,2306	0,5051	-0,3376	-0,4243
Factor 2	0,1541	0,0552	0,0293	0,0243	0,1349	-0,1905	-0,1681	-0,1599	-0,1953	0,4527	0,4552	0,3423	-0,2228	0,364	0,3374
Factor 3	0,0777	-0,2555	0,0814	0,2076	0,0861	-0,0236	0,0804	0,1755	0,337	0,2469	0,2151	-0,6189	-0,4599	-0,1113	0,0776
Factor 4	0,0242	0,2809	-0,5347	-0,1727	-0,1035	-0,3802	-0,2136	-0,1281	0,0308	-0,1668	-0,083	-0,4589	0,0855	0,2509	0,2664
Factor 5	-0,0549	-0,0123	-0,6266	-0,0235	-0,0419	0,0698	0,079	-0,1139	0,4042	0,1356	0,0818	0,3901	-0,1634	-0,4557	0,0543
Auto. valores	Variância %														
3.7401	51,15														
3.0206	41,31														
0.3729	5,1														
0.1244	1,7														
0.0538	0,74														

^aprofundidade (0-0,2 m) e ^bprofundidade (0,2-0,4 m)

O segundo fator regionalizado significativo na escala longa foi associado, principalmente, às bandas do infravermelho termal (bandas 10 e 11) e as bandas de comprimento de onda curta do infravermelho (bandas 6, 7) e sendo que essas foram positivamente correlacionadas. Isso significa que o segundo fator está relacionado ao estresse hídrico da cultura, altas temperaturas (cultura com estresse hídrico) e alta refletância nas bandas que detectam absorção de água. Em ciências agrárias, a avaliação no campo da distribuição espacial do teor de água em escalas grandes é de extrema importância na avaliação da exigência de água pela cultura, visando o manejo de recursos hídricos em sistemas de irrigação. No entanto, o uso desse fator regionalizado para direcionar a irrigação requer uma calibração adequada.

As Figuras 80, 81 e 82 o primeiro fator regionalizado em escala curta, o primeiro e o segundo fator em escala longa, respectivamente. Os escores dos fatores foram divididos em três zonas homogêneas de igual tamanho, usando três classes de isofrequência para representar alta, média e baixa presença de variáveis que pesaram positivamente e ou negativamente sobre os fatores regionalizados mapeados. Estas classes representam relativamente zonas com baixa variação, as quais podem auxiliar os agricultores a tomada das melhores decisões em manejos específicos do local, principalmente para a fertilização e irrigação.

O primeiro fator, em curta escala, é caracterizado por áreas alternadas de valores baixos e altos de CTC, argila e MO (Figura 80). Vale a pena ressaltar que, devido às cargas negativas dos coeficientes, as relações dessas variáveis com este fator é invertido. No entanto, a continuidade espacial em zonas homogêneas neste mapa permite seu uso pragmático em agricultura de precisão. É interessante observar que nessa escala a relação entre argila, CTC com MO é positivo, diferentemente do que é observado nos mapas temáticos que mostram a variação acumulada.

As mesmas considerações feitas para o modelo de solo foram mantidas para o primeiro fator do modelo de fusão. O mapa do primeiro fator (Figura 80) mostra-se semelhante à Figura 37 do primeiro fator do modelo de solo, mas com um ligeiro aumento da variabilidade.




Figura 80. Mapa representado em três zonas de manejo (ZMs) para o primeiro fator em escala curta (250 m) para o modelo de fusão.

Os mapas do primeiro e segundo fator em longa escala (Figuras 81 e 82) foram delineados em três zonas homogêneas representadas em alta, média e baixa, valores de reflectância em infravermelho próximo, em onda curta do infravermelho e temperatura. Esses fatores podem ser assumidos como indicadores de conteúdo de água nas folhas e estresse hídrico da cultura, com alta refletância nas bandas 5, 6 e 7 e maior emissão nas bandas 10 e 11, que estão relacionadas ao baixo teor de água.

As zonas definidas no primeiro fator, em escala longa, podem ser interpretadas como regiões do campo que são persistentemente mais úmidas (baixa radiância) e secas (alta radiância), que podem ajudar a orientar a entrada de água mais precisamente para o manejo irrigado. Da mesma forma para o segundo fator, em escala longa, o mapeamento foi definido em regiões do campo que são mais quente (baixo teor de água) e mais frio (alto teor de água), desta forma estas zonas podem auxiliar o agricultor na melhor tomada de decisão na gestão da água.




Figura 81. Mapa em três zonas de manejo (ZMs) de acordo com o primeiro fator em escala longa (750 m) para o modelo de fusão.




Figura 82. Mapa em três zonas de manejo (ZMs) de acordo com o segundo fator em escala longa (750 m) para o modelo de fusão.

7 CONSIDERAÇÕES FINAIS

Análise geoestatística multivariada permitiu separar as diferentes fontes de variação espacial em diferentes escalas. Este método mostrou-se muito útil para uma série de razões principais.

Em primeiro lugar porque ofereceu a oportunidade para a formulação de hipóteses sobre as prováveis fontes de variação do solo e resposta espectral da cultura, então se pode definir como uma vantagem cognitiva. Em segundo lugar, possibilitou uma melhor compreensão das variações dentro da área de estudo, permitindo o desenvolvimento de manejos mais sofisticados do solo e da cultura o que poderia ser definido como uma vantagem operacional na Agricultura de Precisão. Neste último aspecto, a abordagem Análise da Cokrigagem Fatorial demonstrou ser um método altamente eficaz para definir a área em zonas homogêneas, a fim de aperfeiçoar seu manejo.

Atráves das variáveis do solo cokrigadas pode-se definir que a parte ocidental do campo foi caracterizada por uma variabilidade espacial de valores mais elevados para a maioria das variáveis (Ca, CE, CC, MO, S, argila e silte).

O campo foi dividido em zonas homogêneas caracterizadas por diferentes classes texturais e em fertilidade do solo. Foi caracterizado por uma ampla área

central mais textural com a variação espacial dominado por alguns fatores inerentes à gênese do solo e formas de manejo. Outro fator que foi caracterizado na grande área central, por maiores concentrações foram os elementos químicos (Mg, Ca) determinado a fertilidade da área.

Houve o aumento da capacidade de continuidade e previsão espacial que não seria possível usando somente as esparsas observações de solo. Uma das constatações significativas foi em relação aos mapas cokrigados das propriedades do solo, a partir do modelo de fusão, com um aumento da variabilidade devido à introdução das variáveis espectrais em escala fina.

Deve ser dada atenção, na geoestatística multivariada, na definição dos modelos teóricos, que devem ser escolhidos e ajustados com a matriz de variograma e covariograma. A escolha da natureza, número e modelos básicos influenciam grandemente a qualidade do ajuste, em seguida, a interpretação resultante da análise de correionalização.

É necessário o bom ajuste dos modelos teóricos, contudo, não é uma prova da realidade física. No entanto, acredita-se que, quando se utiliza a análise linear de correionalização de forma descritiva, os resultados podem ser considerados consistentes, desde que sejam compatíveis com conhecimento físico prévio e experiência.

8 CONCLUSÕES

Pela abordagem geoestatística multivariada foi analisada a delimitação das Zonas de Manejo (ZMs), em uma área cultivada com cana-de-açúcar, no município de São Manoel-SP, podendo-se concluir:

- ✓ Modelo Linear de Corregionalização permitiu a avaliação dos atributos em diferentes escalas (curta e longa);
- ✓ Pelo método da Cokrigagem Fatorial foi possível discriminar três Zonas de Manejo (ZMs);
- ✓ Do ponto de vista agrônômico, foi possível diferenciar uma zona central em comparação com ao manejo das demais áreas periféricas, porque apresenta uma textura mais fina e mais rica de macronutrientes;
- ✓ Que houve ganho na tomada de decisão quando utiliza-se um conjunto de bandas espectrais, podendo-se aumentar o número de informações sobre alvo;
- ✓ A análise conjunta de dados espectrais multivariados em escala reduzida oriundos do satélite Landsat-8 foi eficaz ao acessar e traduzir os sinais de reflectância em comprimentos específicos de onda em variabilidade espacial e definir Zonas de Manejo (ZMs) para ser aplicada na Agricultura de Precisão;

✓ A abordagem de fusão de dados de solo e de sensoriamento remoto permitiu a redução da escala para estimativas das variáveis de solo, utilizando variáveis secundárias de maior resolução, neste caso os dados de reflectância do Landsat-8;

✓ Os três modelos utilizados foram eficientes na definição das Zonas de Manejo (ZMs), para a melhor tomada de decisão no planejamento da cultura.

9 REFERÊNCIAS

ADAMCHUK, V. I. et al. In Ciza Thomas (Ed.), Sensor fusion for precision agriculture, sensor fusion e Foundation and applications. InTech, ISBN 978-953-307-446-7, 2011. Disponível em: <http://www.intechopen.com/articles/show/title/sensor-fusion-for-precision-agriculture>.

ADAMCHUK, V. **On-the-go soil sensors — are we there yet?** Proceeding of The Second Global Workshop on Proximal Soil Sensing — Montreal, p. 160–163, 2011.

AGGELOPOOULOU, K. et al. Delineation of management zones in an apple orchard in Greece using a multivariate approach. **Computers and Electronics in Agriculture**, Amsterdam, v. 90, p. 119–130, 2013.

AgraFNP. Agrianual 2010 - **Anuário da Agricultura Brasileira**. São Paulo: AgraFNP, 2010.

AHAMED, T. et al. **Site-specific management for biomass feedstock production: development of remote sensing data acquisition systems**. Proceedings of 10th international conference on precision agriculture. Denver Colorado; 18 e 21 Jul 2010.

APARICIO, N. et al. Spectral vegetation indices as non destructive tools for determining durum wheat yield. **Agronomy Journal**, Lleida, Spain; 92: p. 83-91, 2000.

BASSO, B. et al. Criteria for selecting optimal nitrose fertilizer rates for precision agriculture. **Italian Journal of Agronomy**, Pavia, Italy, v. 4, p. 147–158, 2009.

BASSO, B. et al. A strategic and tactical management approach to select optimal N fertilizer rates for wheat in a spatially variable field. **European Journal of Agronomy**. Amsterdam, v. 35, p. 215–222, 2011.

BAUER, M.E. The role of remote sensing in determining the distribution and yield of crops, **Advances in Agronomy**, Newark, USA, v. 27: p. 271–304, 1975.

BRAVERMAN, A. et al. Spatial Statistical Data Fusion for Remote Sensing Applications. **Journal of the American Statistical Association**. London, v. 107, p. 1004–1018, 2012.

BRUNINI, O. Ambientes climáticos e exploração agrícola da cana-de-açúcar. In: DINARDOMIRANDA, L. L.; VASCONCELOS, A.C. M. de; ANDRADE LANDELL, M. G. DE. **Cana-de-açúcar**. Campinas: Instituto Agronômico, 2008. p. 205–218.

CASAGRANDE, A.A.; VASCONCELOS, A.C.M. Fisiologia da parte aérea. In: DINARDO-MIRANDA, L.L.; VASCONCELOS, A.C.M.; LANDELL, G.A. **Cana-de-Açúcar**. 1.ed. Campinas: Instituto Agronômico, 2008. p. 45–56.

CASA, R.; CASTRIGNANÒ, A. Analysis of spatial relationships between soil and crop variables in a durum wheat field using a multivariate geostatistical approach. **European Journal of Agronomy**. Amsterdam, v. 28, p. 331–342, 2008.

CASTRIGNANÒ, A. et al. Study of spatial relationships among some soil physico-chemical properties of a field in central Italy using multivariate geostatistics. **Geoderma**. Amsterdam, v. 97, p. 39–60, 2000.

CASTRIGNANÒ, A.; BUTTAUFUOCO, G.; GIASI, R.C. Assessment of the Risk of Groundwater Salinisation Using Multivariate Geostatistics. *GeoEnv VI—Geostatistics for Environmental Applications*. **Quantitative Geology and Geostatistics**, Springer, Berlin, Germany, v. 15, p. 191–202, 2008.

CASTRIGNANÒ, A. et al. Accounting for extensive topographic and pedologic secondary information to improve soil mapping. **CATENA**, Amsterdam, v. 77, p. 28–38, 2009.

CASTRIGNANÒ, A.; WONG, M.T.F.; GUASTAFERRO, F. **Delineation of management zone using multivariate geostatistics and EMI data as auxiliary variable**, in: Proceedings of the 18th Symposium of the International Scientific Centre of Fertilizers, More Sustainability in Agriculture: New Fertilizers and Fertilization Management, *Fertilitas Agrorum*. p. 241–248, 2010.

CASTRIGNANÒ, A. et al. Use of EMI, gamma-ray emission and GPS height as multi-sensor data for soil characterisation. **Geoderma**. Amsterdam, v. 175–176, p. 78–89, 2012.

CASTRO, P. R. C. Maturadores químicos em cana-de-açúcar. In: semana da cana-de-açúcar de Piracicaba, 4., 1999, Piracicaba. **Anais...** Piracicaba: SACCHARUM, 1999. v. 1, p. 12–16.

CECCATO, P. et al. Detecting vegetation leaf water content using reflectance in the optical domain. **Remote Sensing of Environment**. Amsterdam, v 77, p. 22–33, 2001.

CHAPELLE, E.W.; KIM, M.S.; MCMURTREY, J.E. Ratio analysis of reflectance spectra (RARS): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b and the carotenoids in soybean leaves. **Remote Sensing of Environment**, Amsterdam, v.39, n.3, p.239 -247, Mar. 1992.

CHATTERJEE, A. et al. A geostatistical data fusion technique for merging remote sensing and groundbased observations of aerosol optical thickness. **Journal Of Geophysical Research**, USA, v. 115, D20207, doi:10.1029/2009JD013765, 2010.

CHEN, D., HUANG, J., JACKSON, T.J. Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. **Remote Sensing of Environment**, Amsterdam, v. 98, p. 225–236, 2005.

CHILÈS, J.P., DELFINER, P. **Geoestatics: Modeling spatial uncertainty**. New York: Wiley. 1999. 695 pp.

CHILÈS, J.P., DELFINER, P. **Geoestatics: Modeling spatial uncertainty**. New York: Wiley. 2012. 702 pp.

CENTRO INTEGRADO DE INFORMAÇÕES AGROMETEOROLÓGICAS (CIIAGRO) Online [homepage on the internet]. São Paulo: Instituto Agrônomo; c1988-2003 [cited 2007 Apr. 10]. Available from: <http://www.ciiagro.sp.gov.br/ciiagroonline/>.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Avaliação da safra 2014/2015 da cana-de-açúcar**. 2014.

CORWIN, D.L.; LESCH, S.M. Application of soil electrical conductivity to precision agriculture: theory, principles, and guidelines. **Agronomy Journal**, Washington, v. 95: p. 455–471, 2003.

DATT, B. Remote sensing of water content in eucalyptus leaves. **Australian Journal of Botany**, Sydney, v. 47 (6), p. 909–923, 1999.

DE BENEDETTO, D. et al. An approach for delineating homogeneous zones by using multi-sensor data. **Geoderma**, Amsterdam, v. 199, p. 117–127, 2013.

DE BENEDETTO, D. **Application and integration of geophysical techniques for estimating soil water content**. 2014. 295 f. Tese (Doutorado em Ciência da Terra) Università degli studi di Bari Aldo Moro. Bari, Italia, 2014.

DI FONZO, N. et al. **Crop management efficiency as a tool to improve durum wheat quality in Mediterranean areas**. In: Abecassis, J., Autran, J.C., Feillet, P. (Eds.), *Durum Wheat, Semolina and Pasta Quality: Recent Achievements and New Trends*. INRA, Paris 20, Les Colloques n° 99, p. 67–82, 2001.

DIACONO, M. et al. Spatial and temporal variability of wheat grain yield and quality in a Mediterranean environment: A multivariate geostatistical approach. **Field Crops Research**, Amsterdam, v. 131, p. 49–62, 2012.

DIACONO, M. et al. A combined approach of geostatistics and geographical clustering for delineating homogeneous zones in a durum wheat field in organic farming. **NJAS - Wageningen J. Life Sci.** Amsterdam. v. 64-65, p. 47-57, 2013.

DURRANT-WHYTE, H. **Multi Sensor Data Fusion**. Australian Centre for Field Robotics, Univ. Sydney. Version 1.2, 2001.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Manual de métodos de análise de solo**. Centro Nacional de Pesquisa de Solo. 2.ed. Rio de Janeiro: Embrapa CNPS, 1997. 212p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema brasileiro de classificação de solos**. 3.ed. Brasília, Produção de Informação, 2013. 353p.

FALKER MAP/FALKER MAP PLUS. **Software para Geração de Mapas FMP7000/7500**. Revisão B. 2011.

FOOD AND AGRICULTURE ORGANIZATION - FAO. **Human Energy Requirements**, Report. 2005.

FIORIO, P. R.; DEMATTE, J. A. M.; SPAROVEK, G. Chronology and environmental impact of land use on Cerveiro microbasin in Piracicaba region, Brazil. **Pesquisa Agropecuária Brasileira**, Brasília. v. 35, p. 671– 679, 2000.

FRAISSE, C.W.; SUDDUTH, K.A.; KITCHEN, N.R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **Trans. Am. Soc. Agric. Biol. Eng.** v. 44, p. 155–166, 2001.

FRANZEN, D.W. Evaluation of soil survey scale for zone development of site-specific nitrogen management. **Agron. J**, USA. v. 94, p. 381–389, 2002.

FROGBROOK, Z.L.; OLIVER, M.A. Comparing the spatial prediction of soil organic matter by two laboratory methods. **Soil Use and Management**, London. V. 17. p. 235-244, 2001.

FRIDGEN, J.J. Management zone analyst (MZA): software for subfield management zone delineation. **Agron. J**, USA. v. 96, p. 100–108, 2004.

GAUSMAN, H.W.; ALLEN, W.A., ESCOBAR, D.E. Refractive index of plant-cell walls, **Applied Optics**, Massachusetts. v. 13, n. (1): p. 109–111, 1974.

GAUSMAN, H.W., RODRIGUEZ, R.R., RICHARDSON, A.J. Infiniterefectance of dead compared with live vegetation, **Agronomy Journal**, USA. v. 68, n. (2): p. 295–296. 1976.

GAUSMAN, H.W. Optical-parameters of leaves of 7 weed species, **Weed Science**, USA. v. 29, n. (1): p. 24–26, 1981.

GEBBERS, R.; ADAMCHUK, V.I. Precision agriculture and food security. **Science**, Montreal. v. 3, n. 27, p. 828-831, 2010.

GEOVARIANCES, Ecole Des Mines De Paris, 2014. Isatis Technical Ref., release 10.04. Geovariances, Avon Cedex, France.

GITELSON, A.A. Wide Dynamic Range Vegetation Index for Remote Quantification of Biophysical Characteristics of Vegetation. **J. Plant Physiol**, Amsterdam. v. 161. p. 165–173, 2004.

GOLDEMBERG, J.; COELHO, S. T.; GUARDABASSI, P. The sustainability of ethanol production from sugarcane. **Energy Policy**, Amsterdam. v.36, p. 2086-2097, 2008.

GODWIN, R.J.; MILLER, P.C.H. A review of the technologies for mapping within field variability. **Biosyst. Eng**, USA. v. 84, p. 393–407, 2003.

GODOY, A. A. **Modelagem de processos de acumulação de biomassa e de açúcar de açúcar da cana-de-açúcar via sistemas nebulosos**. 2007. 254 p. Dissertação (Mestrado em Engenharia Elétrica), Universidade Estadual de Campinas, Campinas, 2007.

GOOVAERTS, P. **Geostatistics for natural resources evaluation. Applied Geostatistics Series**. Oxford Univ. Press, Oxford.1997. 483 p.

GOOVAERTS, P. Ordinary Cokriging Revisited. **Mathematical Geology**, Montreal. v. 30, n. 1, 1998.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**, Amsterdam. v. 228, p. 113-129, 2000.

GUASTAFERRO, F.; CASTRIGNANÒ, A.; DE BENEDETTO, D.; SOLLITTO, D.; TROCCOLI, A.; CAFARELLI, B. A comparison of different algorithms for the delineation of management zones. **Precision Agriculture**, Amsterdam. v. 11, p. 600-620. 2010.

HABOUDANE, D. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, Amsterdam. v. 90, p.337–352, 2004.

HARRY, V. Principles of soil and plant water relations. **Geoderma**, Amsterdam. v. 133, n. (3–4), 478 p., 2006.

HISSA, L. B. **Modelagem espacial da produtividade e rentabilidade econômica do cultivo de cana-de-açúcar para o Brasil e para a Região MAP**. 2011, 74 p. Dissertação (Mestrado em Análise e Modelagem de Sistemas Ambientais), Universidade Federal de Minas Gerais. Belo Horizonte, 2011.

HENGL, T.; HEUVELINK, G.B.M.; STEIN, A. A generic framework for spatial prediction of soil variables based on regression-kriging. **Geoderma**, Amsterdam. v. 120, p. 75-93, 2004.

HENGL, T.; HEUVELINK, G.B.M.; ROSSITER, D.G. About regression-kriging: from equations to case studies. **Computers and Geosciences**. Amsterdam. v. 33, n. 10, p. 1301–1315, 2007.

HOUBORG, R.; ANDERSON, M.; DAUGHTRY, C. Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. **Remote Sensing of Environment**, Amsterdam. v.113, p. 259–274, 2009.

HOUBORG, R. et al. Using leaf chlorophyll to parameterize light-use-efficiency within a thermal-based carbon, water and energy exchange model. **Remote Sensing of Environment**, Amsterdam. v. 115, n. 7, p. 1694–1705, 2011.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **PAM: Produção Agrícola Municipal**, 2010. Disponível em: <www.sidra.ibge.gov.br>. Acessado em: 23 de outubro 2013.

ISAAKS, E.H.; SRIVASTAVA, R.M. **An introduction to applied geostatistics**. New York: Oxford University Press, 1989. 561p.

JONES, H.G. et al. Use of infrared thermometry for monitoring stomatal closure in the field: application to grapevine. **Journal of Experimental Botany**, London. v. 53, p. 2240–2260, 2002.

JONES, H.G. Application of thermal imaging and infrared sensing in plant physiology and ecophysiology. **Adv. Bot. Res**, London. v. 41, p. 107–163, 2004.

JONCKHEERE, I. et al. Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. **Agricultural and Forest Meteorology**, v. 121, p. 19–35, 2004.

JOURNEL, A.G.; HUIJBREGTS, C.J. **Mining geostatistics**. Academic Press, New York, 1978. 600p.

KNIPLING, E.B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation, **Remote Sensing of Environment**, Amsterdam. v. 1, p. 155–159, 1970.

KNUDSON E. J. et al. **Application of factor analysis to the study of rain chemistry in the Puget Sound region**. In Chemometric: Theory and Application, ed. B. R. Kowalski, pp. 80±116. ACS Symposium Series, Washington, DC.1977.

LARK, R.M. Forming spatially coherent regions by classification of multivariate data: an example from the analysis of maps of crop yield. **Int. J. Geogr. Inf. Sci**, Berlin. v. 12, p. 83–98, 1998.

LEINONEN, I.; JONES, H.G. Combining thermal and visible imagery for estimating canopy temperature and identifying plant stress. **Journal of Experimental Botany**, London. v. 55, p. 1423–1431, 2004.

LEPSCH, I. F. **Influência dos fatores edáficos na produção.** In: CASTRO, P. R. C.; FERREIRA, S. O.; YAMADA, T.; (Coord.). *Ecofisiologia da produção*. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fosfato (POTAFOS), 1987. p. 83-98.

LÓPEZ-LOZANO, R.; CASTERAD, M.A.; HERRERO, J. Site-specific management units in a commercial maize plot delineated using very high resolution remote sensing and soil properties mapping. **Computers and Electronics in Agriculture**, Amsterdam. v. 73, p. 219–229, 2010.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO (MAPA). **Projeções do Agronegócio 2008/2009 a 2019/2020.** Brasília, 2010. Disponível em www.agricultura.gov.br. Acessado em: 12 de junho 2014.

MARCHIORI, L. F. S. **Influência da época de plantio e corte na produtividade da cana-de-açúcar.** 2004. 275 f. Tese (Doutorado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2004.

MATHERON, G. **The theory of regionalised variables and its applications.** Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau 5. Paris. 1971.

MATHERON, G. The intrinsic random functions and their applications. **Advances in Applied probability**, v. 5, p. 239-465, 1973.

MATHERON, G. **Pour une analyse krigée des données régionalisées.** Technical Report No. 732. Centre de Geostatistique, Fontainebleau. 1982.

McBRATNEY, A.B.; WEBSTER, R. The design of optimal sampling schemes for local estimation and mapping of regionalized variables. II. Program and examples. **Computers and Geosciences**, Amsterdam. v. 5, p. 335-365. 1981.

McBRATNEY, A.B. et al. An overview of pedometric techniques for use in soil survey. **Geoderma**, Amsterdam. v. 97, p. 293–327, 2000.

MILNE, A.E. et al. Spatial multivariate classification of an arable field into compact management zones based on past crop yields. **Computers and Electronics in Agriculture**, Amsterdam. v. 80, p. 17–30, 2012.

MITAS, L.; MITASOVA, H. Spatial interpolation. In: Longley, P., Goodchild, M., Maguire, D., Rhind, D. (Eds.). **Geographical Information System: Principles, Techniques, Management and Applications**, vol. 1. Wiley, London: 481-492, 1999.

MOLLER, M. Use of thermal and visible imagery for estimating crop water status of irrigated grapevine. **Journal of Experimental Botany**, London. v. 58, n. 4, p. 827–838, 2007.

MORAN, M.S.; INOUE, Y.; BARNES, E.M. Opportunities and limitations for imagebased remote sensing in precision crop management. **Remote Sensing of Environment**, Amsterdam. v. 61, p. 319–346, 1997.

MORARI, F.; CASTRIGNANÒ, A.; PAGLIARIN, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. **Computers and Electronics in Agriculture**, Amsterdam. v. 68, p. 97–107, 2009.

MIRZAIE, M. et al. Comparative analysis of different uni- and multi-variate methods forestimation of vegetation water content using hyper-spectral measurements. **International Journal of Applied Earth Observation and Geoinformation**, London. v. 26, p.1–11, 2014.

MOLIN, J. P. **Agricultura de precisão: o gerenciamento da variabilidade**. Piracicaba: O Autor, 2001. 83 p.

MZUKUET, M. et al. Spatial variability of measured soil properties across site-specific management zones. **Soil Sci. Soc. Am. J**, USA. v. 69, p. 1572–1579. 2005.

NASCIMENTO, C. M.; PEREIRA, M. A. M. G. **Atlas climatológico do estado de São Paulo**. Campinas, Fundação Cargill, 1988. 93p

OLIVER, M.A. (Ed.). **Geostatistical Applications for Precision Agriculture**. Springer, Dordrecht. 2010.

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.

PINTER, JR., P.J. et al. The Agricultural Research Service's remote sensing program: An example of interagency collaboration, **Photogrammetric Engineering and Remote Sensing**, San Diego. v. 69, n. 6, p. 615–618, 2003.

PINTO, M.C.F. **Manual Medição in loco: Temperatura, pH, Condutividade Elétrica e Oxigênio Dissolvido**. Serviço Geológico do Brasil, 2007.

PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: A. Silva Vieira Ed., 2007.

PRICE, J.C. On the information-content of soil reflectance spectra, **Remote Sensing of Environment**, Amsterdam. v. 33, n. 2, p. 113–121, 1990.

RIBEIRO JUNIOR, P. J. **Métodos geoestatísticos no estudo da variabilidade espacial de variáveis do solo**. 1995. 99 f. Dissertação (Mestrado em Agronomia)-Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 1995.

RIVOIRARD, J. Which models for collocated cokriging. **Mathematical Geology**, Montreal. v. 33, p. 117–131, 2001.

ROBERT, P.C. Characterization of soil conditions at the field level for soil specific management. **Geoderma**, Amsterdam. v. 60, p. 57-72, 1993.

ROSSATO, O.B. **Metodologias de avaliação e aplicação de nutrientes nas culturas de cana-de-açúcar e algodão**. 2011. 98 f. Tese (Doutorado) - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2011.

ROUDIER, P. et al. A technical opportunity index adapted to zone-specific management. **Precision Agric**, Amsterdam. v. 12, p. 130–145, 2011.

ROYLE, J.A.; BERLINER, L.M.A **Hierarchical Approach to Multivariate Spatial Modeling and Prediction**. Technical report n°. 619, Dept. of Statistics, Ohio StateUniversity. 1999.

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.

SAS Institute Inc, 2013. SAS/STAT software Release 9.3. Cary, NC, USA.

SCUDIERO, E. et al. Delineation of site-specific management units in a saline region at the Venice Lagoon margin, Italy, using soil reflectance and apparent electrical conductivity. **Computers and Electronics in Agriculture**, Amsterdam. v. 99, p. 54–64, 2013.

SEELAN, S.K. et al. Remote sensing applications for precision agriculture: a learning community approach. **Remote Sensing of Environment**, Amsterdam. v. 88, p. 157–169, 2003.

SEGATO, S. V et al. **Atualização em produção de cana-de-açúcar**.Piracicaba-SP. ND-LIVROCERES, 2006.

SEPULCRE-CANTÓ, G. et al. Detection of water stress in an olive orchard with thermal remote sensing imagery. **Agr.Forest Meteorol**, USA. v. 136, n. 1–2, p. 31–44, 2006.

SILVERMAN, B.W. Density Estimation. Chapman and Hall, New York.1986.

SIMOS, N.; COSTANTINO, C. J. Soil Spatial Variability Effect on Soil Structure Interaction Studies: Enveloping Uncertainties in Structural Response. **Proceedings, Third UJNR Workshop on Soil-Structure Interaction**, March 29-30, 2004, Menlo Park, California, USA.

SIMS, D.A., GAMON, J.A. Estimation of vegetation water content and photosyn-thetic tissue area from spectral reflectance: a comparison of indices based onliquid water and chlorophyll absorption features. **Remote Sensing of Environment**, Amsterdam. v. 84, p. 526–537, 2002.

SLATON, M.R.; HUNT,E.R.; SMITH ,W.K. Estimating near infrared leaf reflectance from leaf structural characteristics, **American Journal of Botany**, USA. v. 88, n. 2, p. 278–284, 2001.

SMITH, F. An empirical law describing heterogeneity in the yields of agricultural crops. **Journal of Agricultural Science**, USA. v. 28, p. 1–23, 1938.

STAFFORD, J.V.; BOLAM, H.C. **Near-ground and aerial radiometry imaging for assessing spatial variability in crop condition**. In: Robert, P.C., et al. (Eds.), *Proceedings of the 4th International Conference on Precision Agriculture*. ASA, CSSA, and SSSA, Madison, WI, p. 291–302, 1998.

STAFFORD, J.V. Implementing precision agriculture in the 21st century. **J. Agric. Eng. Res.** USA. v. 76, p. 267–275, 2000.

SUMMERS, D.; LEWISA, M.; OSTENDORF, B.; CHITTLEBOROUGH, D. Visible near-infrared reflectance spectroscopy as a predictive indicator of soil properties. **Ecological Indicators**, Amsterdam, v. 11, n. 1, p. 123–131, 2011.

THENKABAIL, P.; LYON, J.G.; HUETE, A. **Hyperspectral Remote Sensing of Vegetation**. Taylor e Francis Group. 2012.

TAYLOR, J.A.; McBRATNEY, A.B.; WHELAN, B.M. Establishing management classes for broad acre agricultural production, **Agron. J.** Amsterdam. v. 99, p. 1366–1376, 2007.

TAYLOR, J.A., SHORT, M., MCBRATNEY, A.B., WILSON, J. Comparing the ability of multisoil sensors to predict soil properties in a Scottish Potato Production System. Proximal soil sensing. *Progress in Soil Science* 1 (Part 6), p. 387–396, 2010. http://dx.doi.org/10.1007/978-90-481-8859-8_33.

TRIANTAFILLIS, J.; LASLETT, G. M.; MCBRATNEY, A. B. Calibrating an electromagnetic induction instrument to measure salinity in soil under irrigated cotton. **Soil Science Society America Journal**, USA. v. 64, p. 1009–1017, 2000.

UNITED STATES GEOLOGICAL SURVEY (USGS). Disponível em <http://earthexplorer.usgs.gov/> Acesso em 22 Out. 2014.

UNIÃO DA INDÚSTRIA DA CANA-DE-AÇÚCAR (ÚNICA). **Produção de cana-de-açúcar no Brasil** (1990/1991 a 2012/2013). Disponível em www.unica.com.br/dadosCotacao/estatistica/ Último acesso em 20 de ago. 2013.

VIDAL, R.A.; TREZZI, M.M. Origem da cultura e sua importância. In: **Teoria e prática do manejo de infestantes na cultura da cana-de-açúcar no Brasil**. Porto Alegre: Ribas a. Vidal, 2011, 136 p.

VIEIRA, S. R. **Uso da geoestatística em estudos de variabilidade espacial**. Campinas: IAC, 1995. 61 p.

VRINDTS, E. et al. Analysis of soil and crop properties for precision agriculture for winter wheat. **Biosyst. Eng.** London. v. 85, p. 141–152, 2003.

WACKERNAGEL, H. Geostatistical techniques for interpreting multivariate spatial information. In: Quantative analysis of mineral and energy resources. Chung, C. F., Fabbri, A. G., and Sinding-Larsen, R. (eds). Reidal, Dordrecht, **The Netherlands**, Amsterdam. p. 393 – 409, 1988.

WACKERNAGEL, H. **Multivariate Geostatistics: an introduction with Applications**. Springer-Verlag, Berlin. 2003. 388 pp.

WEBSTER, R.; OLIVER, M.A. **Geostatistics for Environmental Scientists**. Wiley, Chichester. 2001.

WIEGAND, C. et al. Soil salinity effects on crop growth and yield: Illustration of an analysis and mapping methodology for sugarcane. **Journal of Plant Physiology**, Amsterdam. v. 148, p. 418– 424, 1996.

YANG, X. H.; ZHOU, Q. M.; MELVILLE, M. Estimating local sugarcane evapotranspiration using Landsat TM image and a VITT concept. **International Journal of Remote Sensing**, New Delhi, India. v. 18, p. 453– 459, 1997.

YAN, L. et al. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, Amsterdam. v. 56, p. 174–186, 2007.

ZYGIELBAUM, A.I. et al. Nondestructive detection of water stress and estimation of relative water content in maize. **Geophys.** Nebraska. v. 36, p. 1-4, 2009.