

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – UNIOESTE
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS – CAMPUS CASCAVEL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

UTILIZAÇÃO DE MÉTODOS DE INTERPOLAÇÃO E AGRUPAMENTO PARA
DEFINIÇÃO DE UNIDADES DE MANEJO EM AGRICULTURA DE PRECISÃO

KELYN SCHENATTO

CASCAVEL, PR

2014

KELYN SCHENATTO

**UTILIZAÇÃO DE MÉTODOS DE INTERPOLAÇÃO E AGRUPAMENTO PARA
DEFINIÇÃO DE UNIDADES DE MANEJO EM AGRICULTURA DE PRECISÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento aos requisitos para obtenção do título de Mestre em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Eduardo Godoy de Souza

CASCADEL, PR

2014

Dados Internacionais de Catalogação-na-Publicação (CIP)
Ficha catalográfica elaborada por Jeanine da Silva Barros CRB-9/1362

S346u Schenatto, Kelyn
Utilização de métodos de interpolação e agrupamento para definição de unidades de manejo em agricultura de precisão. / Kelyn Schenatto — Cascavel, PR: UNIOESTE, 2014.
100 f. ; 30 cm.

Orientador: Prof. Dr. Eduardo Godoy de Souza
Dissertação (Mestrado) – Universidade Estadual do Oeste do Paraná.
Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola, Centro de Ciências Exatas e Tecnológicas.
Bibliografia.

1. Krigagem. 2. Zonas de Manejo. 3. K-Means. 4. Fuzzy C-Means. I. Universidade Estadual do Oeste do Paraná. II. Título.

CDD 21. ed. 631.4


Revisão de Língua Portuguesa e das Normas de Edição conforme requisitos do PGEAGRI:
Profa. Ms. Maricélia Nunes dos Santos, em 24 de março de 2014.
Revisão de Língua Inglesa: Prof. José Carlos da Costa, em 21 de março de 2014.

KELYN SCHENATTO

"Utilização de métodos de interpolação e agrupamento para definição de unidades de manejo em agriculturas de precisão "

Dissertação apresentada ao Programa de Pós-Graduação "*Stricto Sensu*" em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Mestre em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, **aprovada** pela seguinte banca examinadora:


Orientadora: Prof. Dr. Eduardo Godoy de Souza
Centro de Ciências Exatas e Tecnológicas, Unioeste


Prof. Dr. Alberto Kazushi Nagaoka
Universidade Federal de Santa Catarina


Prof. Dr. Marcio Furlan Maggi
Centro de Ciências Exatas e Tecnológicas, Unioeste


Prof. Dr. Erivelto Mercante
Centro de Ciências Exatas e Tecnológicas, Unioeste

Cascavel, 04 de fevereiro de 2014.

BIOGRAFIA

Kelyn Schenatto nasceu no dia 14 de fevereiro de 1991 na cidade de Medianeira, PR. No ano de 2011, concluiu o curso de Graduação Tecnologia em Análise e Desenvolvimento de Sistemas, pela Universidade Tecnológica Federal do Paraná (UTFPR, campus Medianeira). Em 2012, ingressou no curso de Pós-Graduação em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, nível de mestrado, na Universidade Estadual do Oeste do Paraná (UNIOESTE, campus Cascavel), como bolsista da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Se você quer chegar aonde a maioria não chega, faça aquilo que a maioria não faz.

Bill Gates

Dedico este trabalho aos meus pais, WANDERLEI SCHENATTO e MARISETE FÁTIMA SCHENATTO, que em nenhum momento mediram esforços para a realização dos meus sonhos.

AMO VOCÊS!

AGRADECIMENTOS

Agradeço primeiramente a DEUS, por ter me dado forças e iluminado meu caminho para que eu pudesse concluir mais essa etapa da minha vida.

Ao meu orientador, EDUARDO GODOY DE SOUZA, pelo ensinamento, a dedicação e o auxílio prestados durante a concretização desse trabalho, MUITO OBRIGADA.

À UNIOESTE, em especial ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade de crescimento profissional e pessoal, e à CAPES, pelo apoio concedido para o desenvolvimento deste trabalho.

Ao engenheiro ALDO TASCA, pela cessão de uma das áreas experimentais utilizadas neste trabalho.

A todos os amigos e colegas de laboratório, que de alguma forma contribuíram no desenvolvimento desta pesquisa, em especial, DARLISSON BENTES, DAVI MARCONDES ROCHA, DENILSON BAUMGARTNER, ELOI GASPARIN, JOÃO PAULO THOMAS, LUAN DE PAULA, NELSON MIGUEL BETZEK, RAFAELA NICOLAU e VANDERLEI ARTHUR BIER, pelo apoio e colaboração.

A todos os PROFESSORES do Programa de Pós-Graduação em Engenharia Agrícola, pelos ensinamentos disponibilizados nas aulas; cada um de forma especial contribuiu para a conclusão desse trabalho e conseqüentemente para minha formação profissional.

De forma especial, ao CLAUDIO, pelo amor, carinho e apoio, pela dedicação em me auxiliar na realização do meu trabalho e por estar sempre me apoiando ao longo dessa caminhada.

À minha família, em especial aos meus pais, WANDERLEI E MARISETE, e a minha irmã, KEILA, um enorme obrigada por acreditarem sempre em mim e naquilo que faço e por todos os ensinamentos de vida. Espero que esta etapa, que agora termino, possa, de alguma forma, retribuir e compensar todo o carinho, o apoio e a dedicação que, constantemente, me oferecem.

Por fim, gostaria de agradecer a todos que contribuíram direta ou indiretamente para que esse trabalho fosse realizado, a todos o meu eterno AGRADECIMENTO.

UTILIZAÇÃO DE MÉTODOS DE INTERPOLAÇÃO E AGRUPAMENTO PARA DEFINIÇÃO DE UNIDADES DE MANEJO EM AGRICULTURA DE PRECISÃO

RESUMO

Apesar dos benefícios proporcionados pela tecnologia de agricultura de precisão (AP), a necessidade de grades amostrais densas e uso de equipamentos sofisticados para o manejo do solo e da planta tornam o seu cultivo em muitos casos inviável financeiramente, principalmente para pequenos produtores. Com a finalidade de viabilizar a AP, a definição de unidades de manejo (UM) consiste em dividir o talhão em sub-regiões que possuam características físico-químicas semelhantes, onde se pode trabalhar de forma convencional (sem aplicação localizada de insumos), diferenciando-se das outras sub-regiões do talhão. Dessa forma, utilizam-se conceitos de AP, mas adaptam-se alguns procedimentos para a realidade do produtor, não havendo necessidade da substituição de máquinas tradicionalmente utilizadas. Para isso, são geralmente correlacionados atributos físicos e químicos com a produtividade das culturas e, por meio de métodos estatísticos e geoestatísticos, selecionam-se atributos que darão origem a mapas temáticos posteriormente utilizados para definição das UM. Na etapa de geração dos mapas temáticos, são normalmente utilizados métodos tradicionais de interpolação (inverso da distância – ID, inverso da distância ao quadrado – IDQ e krigagem – KRI) e é importante avaliar se a qualidade dos mapas temáticos gerados influencia no processo de definição das UM, podendo desta forma não se justificar a interpolação de dados a partir do uso de métodos robustos como a KRI. O presente trabalho teve como objetivo a avaliação de três métodos de interpolação (ID, IQD e KRI) para definição dos mapas temáticos utilizados na confecção de UM pelos métodos de agrupamento K-Means e Fuzzy C-Means, em duas áreas experimentais (de 9,9 ha e 15,5 ha), sendo utilizados dados de quatro safras (três safras de soja e uma de milho). Os interpoladores ID e KRI apresentaram UM similares. A concordância entre os mapas diminuiu quando houve aumento do número de classes, mas teve maior intensidade com o método Fuzzy C-Means. Os algoritmos de agrupamento K-Means e Fuzzy C-Means se apresentaram similares na divisão em duas UM. O melhor método de interpolação foi a KRI, seguida do ID, o que justifica a escolha do interpolador mais robusto (KRI) na geração de UM.

Palavras-chave: krigagem, zonas de manejo, K-Means, Fuzzy C-Means.

INTERPOLATOR METHOD AND CLUSTERING TO DEFINITION OF MANAGEMENT ZONES ON PRECISION AGRICULTURE

ABSTRACT

Despite the benefits offered by the technology of precision agriculture (PA), the necessity of dense sampling grids and use of sophisticated equipment for the soil and plant handling make it financially unfeasible in many cases, especially for small producers. With the aim of making viable the PA, the definition of management zones (MZ) consists in dividing the plot in subregions that have similar physicochemical features, where it is possible to work in the conventional manner (without site-specific input application), differing them from the other sub-regions of the field. Thus we use concepts from PA, but adapting some procedures to the reality of the producer, not requiring the replacement of machinery traditionally used. Therefore, yield is usually correlated with physical and chemical properties through statistical and geostatistical methods, and attributes are selected to generate thematic maps, which are then used to define the MZ. In the generation of thematic maps step, are commonly used traditional interpolation methods (Inverse Distance - ID, inverse of the square distance - ISD, and kriging - KRI), and it is important to assess if the quality of thematic maps generated influences in the MZ drafting process and can not justify the interpolation data using robust methods such as KRI. Thus, the present study aimed to evaluate three interpolation methods (ID, ISD and KRI) for generation of thematic maps used in the generation of MZ by clustering methods K-Means and Fuzzy C-Means, in two experimental areas (9.9 ha and 15.5 ha), and been used data from four seasons (three crops of soybeans and one of corn). The KRI interpolation and ID showed similar UM. The agreement between the maps decreased when an increase in the number of classes, but with greater intensity with the Fuzzy C-Means method. Clustering algorithms K-Means and Fuzzy C-Means performed similar division on two UM. The best interpolation method was KRI following the ID, what justifies the choice of a more robust interpolation (KRI) to generate UM.

Keywords: krigagem, management zones, K-Means, Fuzzy C-Means

SUMÁRIO

1	INTRODUÇÃO.....	1
2	OBJETIVOS.....	2
2.1	Objetivo geral.....	2
2.2	Objetivos específicos.....	2
3	REVISÃO BIBLIOGRÁFICA.....	3
3.1	Culturas.....	3
3.1.1	Soja.....	3
3.1.2	Milho.....	4
3.2	Atributos do solo.....	4
3.2.1	Atributos físicos do solo.....	5
3.2.2	Atributos químicos do solo.....	6
3.3	Agricultura de precisão.....	7
3.4	Geoestatística.....	8
3.5	Métodos de interpolação.....	9
3.6	Unidades de manejo.....	11
3.7	Métodos para geração de unidades de manejo.....	12
3.8	Avaliação de unidades de manejo.....	13
3.9	Comparação de mapas temáticos.....	13
4	MATERIAL E MÉTODOS.....	16
4.1	Áreas experimentais.....	16
4.2	Grades amostrais.....	19
4.3	Atributos químicos e físicos do solo.....	21
4.4	Adubação e culturas.....	22
4.5	Mapeamento da produtividade.....	22
4.5.1	Filtragem de dados da colhedora.....	22
4.5.2	Determinação manual da produtividade.....	24
4.6	Análise descritiva e exploratória dos dados.....	24
4.7	Seleção das camadas para geração das unidades de manejo.....	25
4.8	Análise geoestatística.....	26
4.9	Interpolação de dados.....	27
4.10	Definição das unidades de manejo.....	28
4.11	Avaliação das unidades de manejo.....	30
4.12	Comparação dos mapas temáticos.....	30
5	RESULTADOS E DISCUSSÃO.....	32
5.1	Análise química do solo	32
5.2	Análise das propriedades físicas do solo e topografia.....	38

5.3	Análise da produtividade.....	41
5.4	Análise de correlação espacial.....	44
5.5	Análise geoestatística.....	50
5.6	Interpolação de dados.....	51
5.7	Definição das UM.....	53
5.8	Avaliação das UM.....	60
5.9	Comparação de mapas temáticos.....	69
6	CONCLUSÕES.....	74
7	REFERÊNCIAS.....	75

LISTA DE TABELAS

Tabela 1	Classificação do coeficiente de efeito pepita	27
Tabela 2	Classificação do grau de concordância do índice Kappa.....	31
Tabela 3	Estatística descritiva dos atributos químicos do solo da área 1 nos anos de 2011 e 2012.....	33
Tabela 4	Níveis de interpretação dos atributos químicos do solo com a porcentagem encontrada dos pontos amostrais, na área experimental 1.....	35
Tabela 5	Estatística descritiva dos atributos químicos do solo da área 2 para o ano de 2012.....	36
Tabela 6	Níveis de interpretação dos atributos químicos do solo com a porcentagem encontrada dos pontos amostrais, na área experimental 2.....	37
Tabela 7	Estatística descritiva dos atributos físicos do solo na área 1 nos anos de 2011 e 2012.....	38
Tabela 8	Classificação da resistência do solo a penetração.....	39
Tabela 9	Estatística descritiva dos atributos físicos do solo da área 2 no ano de 2012.....	41
Tabela 10	Estatística descritiva da produtividade da área 1 para os anos 2011/2012 e 2012/2013.....	42
Tabela 11	Estatística descritiva da produtividade da área 2 para o ano agrícola 2012/2013.....	43
Tabela 12	Ordem de classificação de atributos candidatos à geração de UM.....	44
Tabela 13	Ordem de classificação dos atributos candidatos à geração de UM.....	46
Tabela 14	Ordem de classificação dos atributos candidatos à geração de UM para cultura do milho.....	48
Tabela 15	Parâmetros do semivariograma para escolha do melhor modelo dos atributos selecionados para geração das UM na área 1.....	50
Tabela 16	Parâmetros do semivariograma para escolha do melhor modelo dos atributos selecionados para geração das UM na área 2.....	51
Tabela 17	Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 1 safra 2011/2012, separados por UM e gerada pelo algoritmo K-Means.....	60
Tabela 18	Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 1 safra 2011/2012, separados por UM e gerada pelo algoritmo Fuzzy C-Means.....	61
Tabela 19	Estatística descritiva e eficiência relativa dos dados de produtividade da área 1 safra da soja 2012/2013, separados por UM e gerada pelo algoritmo K-Means.....	62
Tabela 20	Estatística descritiva dos dados de produtividade da área 1 safra da soja 2012/2013, separados por UM, distância e gerada pelo algoritmo Fuzzy C-Means.....	63
Tabela 21	Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 2, separados por UM e gerada pelo algoritmo K-Means.....	64
Tabela 22	Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 2, separados por UM e gerada pelo algoritmo Fuzzy C-Means.....	65

Tabela 23	Estatística descritiva e eficiência relativa dos dados de produtividade do milho na área 2, separados por UM e gerada pelo algoritmo K-Means.....	66
Tabela 24	Estatística descritiva e eficiência relativa dos dados de produtividade do milho na área 2, separados por UM e gerada pelo algoritmo Fuzzy C-Means.....	67
Tabela 25	Maior porcentagem de diferença de área entre os métodos de interpolação ID, IDQ e KRI nas áreas 1 e 2 considerando os métodos de agrupamento K-Means e Fuzzy C-Means.....	68
Tabela 26	Análise de variância e eficiência relativa considerando o método de interpolação (ID, IDQ e KRI).....	69
Tabela 27	Índices Kappa e Tau extraídos da comparação entre mapas gerados por diferentes interpoladores área 1.....	70
Tabela 28	Índices Kappa e Tau extraídos da comparação entre mapas gerados por diferentes interpoladores área 2.....	71
Tabela 29	Índices Kappa e Tau extraídos da comparação entre mapas gerados pelos métodos de agrupamento K-Means e Fuzzy C-Means área 1.....	72
Tabela 30	Índices Kappa e Tau extraídos da comparação entre mapas gerados por K-Means e Fuzzy C-Means área 2 safra da soja 2012/2013.....	73

LISTA DE FIGURAS

Figura 1	Localização da área 1.....	16
Figura 2	Variação mensal de temperatura mínima, temperatura máxima, precipitação e umidade média relativa do ar nos períodos de safra 2011/2012 e 2012/2013 para a região de Cascavel, PR.....	17
Figura 3	Localização da área 2.....	18
Figura 4	Variação mensal de temperatura mínima, temperatura máxima, precipitação e umidade média relativa do ar dos períodos de safra da soja 2012/2013 e milho safrinha 2013 para a região de São Miguel do Iguçu, PR.....	19
Figura 5	Grade amostral utilizada para determinação das características físicas e químicas do solo na área 1.....	20
Figura 6	Grade amostral utilizada para determinação das características físicas e químicas do solo e produtividade das culturas na área 2.....	20
Figura 7	Procedimento de filtragem dos dados brutos da colhedora.....	23
Figura 8	Mapa dos pontos amostrais originais obtidos pela colhedora na área 1 safra de 2011/2012 (a), mapa de pontos amostrais restantes após a eliminação dos pontos inconsistentes (b) e mapa de produtividade da soja (c).....	41
Figura 9	Mapa dos pontos amostrais originais obtidos pela colhedora na área 1 safra de 2012/2013 (a), mapa de pontos amostrais restantes após a eliminação dos pontos inconsistentes (b) e mapa de produtividade da soja (c).....	42
Figura 10	Mapa de produtividade da do milho na área 2 safra 2013.....	43
Figura 11	Mapa de produtividade da soja na área 2 safra da soja 2012/2013.....	43
Figura 12	Matriz de correlação cruzada das variáveis analisadas na área 1 safra da soja 2011/2012.....	45
Figura 13	Matriz de correlação cruzada das variáveis analisadas na área 1 safra da soja 2012/2013.....	47
Figura 14	Matriz de correlação cruzada das variáveis analisadas na área 2 safra da soja 2012/2013 e milho safrinha 2013.....	49
Figura 15	Mapas temáticos do atributo altitude, interpolados por ID (a), IDQ (b) e krigagem (c).....	52
Figura 16	Mapas temáticos do atributo RSP 0-0,1 m, interpolados por ID (a), IDQ (b) e krigagem (c).....	52
Figura 17	Mapas temáticos do atributo Fósforo, interpolados por ID (a), IDQ (b) e krigagem (c).....	52
Figura 18	Mapas temáticos do atributo Densidade, interpolados por ID (a), IDQ (b) e krigagem (c).....	52
Figura 19	Mapas temáticos do atributo Altitude, interpolados por ID (a), IDQ (b) e KRI (c).....	53
Figura 20	Mapas temáticos do atributo Umidade, interpolados por ID (a), IDQ (b) e krigagem (c).....	53
Figura 21	Mapas temáticos do atributo Zinco, interpolados por ID (a), IDQ (b) e krigagem (c).....	53
Figura 22	Unidades de Manejo geradas para área 1 safra 2011/2012 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	54

Figura 23	Unidades de Manejo geradas para área 1 safra 2011/2012 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)	54
Figura 24	Unidades de Manejo geradas para área 1 safra 2011/2012 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	55
Figura 25	Unidades de Manejo geradas para área 1 safra 2011/2012 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	55
Figura 26	Unidades de Manejo geradas para área 1 safra 2012/2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	56
Figura 27	Unidades de Manejo geradas para área 1 safra 2012/2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	56
Figura 28	Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	57
Figura 29	Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	57
Figura 30	Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	58
Figura 31	Unidades de Manejo geradas para área 2 safra do milho 2013 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	58
Figura 32	Unidades de Manejo geradas para área 2 safra do milho 2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	59
Figura 33	Unidades de Manejo geradas para área 2 safra do milho 2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária).....	59

LISTA DE ABREVIATURAS

Al	Alumínio
ANOVA	Análise de Variância
AP	Agricultura de Precisão
B	Boro
C	Carbono
Ca	Cálcio
Cl	Cloro
CTC	Capacidade de Troca Catiônica
Cu	Cobre
CV	Coeficiente de Variação
ER	Eficiência Relativa
Fe	Ferro
GPS	Global Positioning System
ICE	Índice de Comparação de Erros
ID	Inverso da Distância
IDP	Inverso da Distância Elevado a uma Potência
IDQ	Inverso da Distância ao Quadrado
K	Potássio
KCL	Cloreto de Potássio
KRI	Krigagem
M%	Porcentagem de saturação por alumínio
Mg	Magnésio
Mn	Manganês
Mo	Molibdênio
MO	Matéria Orgânica
N	Nitrogênio
N-P-K	Nitrogênio-Fósforo-Potássio
P	Fósforo
pH	Acidez
RSP	Resistência do Solo a Penetração
S	Enxofre
UM	Unidades de Manejo
V%	Porcentagem de saturação por bases
Zn	Zinco

1 INTRODUÇÃO

A agricultura de precisão (AP) consiste na otimização das práticas agrícolas de maneira localizada, considerando a variabilidade espacial das características que influenciam no desenvolvimento das culturas. A implantação da AP objetiva reduzir a quantidade de insumos e otimizar a produção, além de proporcionar a redução dos possíveis impactos ambientais decorrentes da atividade agrícola. Com o tratamento diferenciado em cada local do talhão, é possível produzir sem desperdícios, tanto financeiros como naturais, mantendo-se ou ampliando a produtividade da cultura.

O crescimento contínuo da AP proporcionou o surgimento de máquinas equipadas com sensores e equipamentos que se utilizam de tecnologia avançada, porém normalmente com altos custos de aquisição e manutenção, o que acaba por inviabilizar a sua adoção por pequenos e médios agricultores. Devido aos altos custos, existem algumas incógnitas referentes à viabilidade econômica da AP, que acabam por dificultar sua utilização de forma mais expressiva.

Entre as pesquisas desenvolvidas com vistas à viabilidade econômica da AP, está o desenvolvimento de metodologias, em que são realizadas adaptações dos conceitos de AP, como é o caso da definição de unidades de manejo (UM), as quais objetivam dividir as áreas produtoras em unidades de gerenciamento menores, com características semelhantes, que devem ser tratadas de forma diferenciada e servem como fonte de recomendação e análise.

Qualquer atributo que de alguma forma influencia no desenvolvimento e na produtividade da planta pode ser utilizado para determinação e avaliação de UM.

Dessa forma, diminui-se a quantidade de amostragens e não há necessidade de substituição dos equipamentos utilizados na agricultura convencional, pois em cada UM a correção e a aplicação de insumos são realizadas em taxa uniforme.

Técnicas de análise de agrupamento de dados têm sido utilizadas para definição de UM. Entre os métodos utilizados, estão os algoritmos K-Means e Fuzzy C-Means, os quais permitem a utilização de um conjunto de fatores que influenciam no desenvolvimento das culturas e um alto grau de diferenciação entre classes.

Usualmente, os dados são interpolados e normalizados antes da definição das UM. Os interpoladores mais usados são a krigagem e o inverso da distância elevado a uma potência (IDP). Visto que as UM devem ser utilizadas como fonte de recomendação e análise, interpolações não adequadas podem prejudicar o processo de divisão das sub-regiões.

2 OBJETIVOS

2.1 Objetivo geral

Avaliar a influência de três interpoladores (krigagem ordinária, inverso da distância e inverso da distância ao quadrado) no processo de definição de unidades de manejo.

2.2 Objetivos específicos

- Identificar quais atributos físicos e químicos do solo podem ser utilizados para geração de UM, a partir de dados de produtividade da soja e do milho de duas áreas experimentais;
- Gerar UM por meio dos métodos K-Means e Fuzzy C-Means com os dados interpolados por cada tipo de interpolador;
- Comparar as UM geradas pelos métodos K-Means e Fuzzy C-Means e pelos três interpoladores, utilizando os índices Kappa e Tau;
- Verificar qual UM apresentou melhores resultados por meio de testes de comparação de médias (ANOVA) e redução da variância por meio do cálculo da eficiência relativa (ER);
- Avaliar a necessidade de utilização de um interpolador mais robusto, como a krigagem.

3 REVISÃO BIBLIOGRÁFICA

3.1 Culturas

3.1.1 Soja

A soja (*Glycine max*) é uma das mais importantes culturas da economia mundial, por ser utilizada por diversos setores, como a agroindústria, a indústria química e de alimentos, além de ser fonte alternativa de bicomcombustível (COSTA NETO et al., 2000).

Segundo o USDA (2013a), a previsão da produção mundial de soja na safra de 2013/2014 está em torno de 281 milhões de toneladas em uma área plantada de cerca de 109 milhões de hectares.

No Brasil, a soja é a cultura agrícola que mais cresceu nas últimas décadas e representa cerca de 50% da área plantada de grãos (28,7 milhões de hectares). Além da expansão da área cultivada, devido aos avanços tecnológicos e ao manejo adequado, assim como aos avanços em pesquisas para melhoramento genético de sementes (PATERNIANI, 2001), houve o aumento da produtividade (MAPA, 2013a).

O sucesso na produção pode ser comprovado verificando-se o recorde de 88 milhões de toneladas previstas para a safra de 2013/2014 (CONAB, 2013a). Tal previsão supera o volume de produção previsto pelos Estados Unidos (85 milhões de toneladas), que é tradicionalmente o maior produtor (USDA, 2013a).

A produção brasileira do grão está concentrada em sua maior parte no estado do Mato Grosso com uma produção de 24,4 milhões de toneladas em 7,8 milhões de hectares de área plantada na safra de 2012/2013 (CONAB, 2013b).

O estado do Paraná é o segundo maior produtor brasileiro do grão, com uma produção de 15 milhões de toneladas e 4,7 milhões de hectares de área cultivada, o que corresponde a uma produtividade de 3.200 kg ha⁻¹. Dessa forma, a produtividade no estado fica a frente da média nacional, de 3.000 kg ha⁻¹ (CONAB, 2013b).

Do total de sua produção, o Brasil exporta cerca de 35 milhões de toneladas por ano do grão, sendo que a China é a principal importadora. O consumo interno no país é em sua maior parte na forma de farelo e óleo de soja (CONAB, 2013b).

O Brasil pode aumentar ainda mais a sua participação no mercado internacional de soja, visto que, entre os grandes produtores mundiais dessa oleaginosa, é o único país que tem áreas disponíveis para aumentar a produção (SILVA NETO, 2011).

3.1.2 Milho

O principal destino da produção de milho (*Zea mays*) são as indústrias de rações animais, que representam a maior parte do consumo desse cereal, isto é, cerca de 70% da produção mundial (DUARTE, 2002). O grão é transformado ainda em óleo, farinha, amido, margarina, entre outros produtos alimentícios (MAPA, 2013b).

Segundo estimativas da safra de 2013/2014, a produção mundial de milho será de cerca de 956 milhões de toneladas, sendo os Estados Unidos o maior produtor, com uma estimativa de 352 milhões de toneladas do grão produzidas nessa última safra (USDA, 2013b).

No Brasil, a produção de milho tem-se caracterizado pela divisão em duas épocas de plantio e o grão tem sido cultivado principalmente nas regiões Centro-Oeste, Sudeste e Sul (MAPA, 2013b).

Estima-se que o Brasil alcançará na safra de 2013/2014 uma produção de 78 milhões de toneladas de milho, em uma área cultivada estimada em 15,4 milhões de hectares, o que representa uma produtividade média nacional de 5.064 kg ha⁻¹ (CONAB, 2013a).

O Paraná, atualmente o maior produtor nacional do grão, cultiva uma área de 2,9 milhões de hectares, produzindo 18 milhões de toneladas (safra 2012/2013), e tem uma produtividade média de 6.200 kg ha⁻¹ (CONAB, 2013b).

A previsão é de que na safra de 2013/2014 o Brasil exporte até 18 milhões de toneladas de milho e consuma aproximadamente 53 milhões de toneladas do grão, atendendo principalmente o consumo humano e a fabricação de rações animais (CONAB, 2013a).

3.2 Atributos do solo

A produtividade de uma área agrícola é influenciada, entre outros fatores, pelas propriedades físicas e químicas do solo (SILVA; CHAVES, 2001). Um solo, para ser considerado fértil, deve ter a capacidade de suprir as necessidades de água e nutrientes em quantidade e proporção adequadas para o crescimento e desenvolvimento das plantas (REICHERT; SILVA; SANTOS, 2009).

Segundo Carvalho, Takeda e Freddi (2003), o solo apresenta variabilidade espacial e temporal de seus atributos, resultante da interação dos processos que comandam os fatores responsáveis por sua formação.

Para Teixeira, Quaggio e Mellis (2011), de forma geral, a variabilidade dos atributos químicos e físicos do solo influencia na qualidade dos produtos agrícolas. Esses fatores

interferem principalmente na disponibilidade de nutrientes e no condicionamento para o crescimento ideal das plantas por meio do ganho de eficiência dos fertilizantes.

Conforme Bottega et al. (2013), é indispensável a caracterização dos atributos químicos e físicos do solo por meio de amostragens capazes de representar tais variações.

3.2.1 Atributos físicos do solo

As propriedades físicas referem-se às condições do solo que permitem a infiltração, a retenção e a disponibilização de água às plantas (REICHERT; REINERT; BRAIDA, 2003). Essas propriedades possuem grande importância, pois influenciam no desenvolvimento das plantas e podem ser alteradas de acordo com o sistema de manejo empregado, que de acordo com Schaffrath et al. (2008) é uma das fontes mais importantes da variabilidade espacial dos atributos físicos do solo.

Segundo Dexter e Youngs (1992), a compreensão e quantificação do impacto do uso e manejo do solo na sua qualidade física são fundamentais no desenvolvimento de sistemas agrícolas sustentáveis.

As técnicas de cultivo com mecanização intensa e a elevada taxa de uso dos solos têm promovido mudanças no comportamento dos seus atributos físicos, o que, conseqüentemente, influencia a produção, o equilíbrio dos recursos naturais e a dinâmica da água no solo (GOMES et al., 2007).

Atributos físico-hídricos, como densidade, macro e micro-porosidade e porosidade total, permitem verificar se o solo apresenta condições adequadas para o desenvolvimento das plantas, indicando se há problemas de compactação (RAMIREZ-LOPEZ; REINA-SANCHEZ; CAMACHO-TAMAYO, 2008). Além disso, fornecem informações importantes para estimativa da suscetibilidade do solo à erosão, projetos de irrigação e também para o estabelecimento de sistemas de manejo do solo e da água (DALBIANCO, 2009), servindo como um indicador eficiente da qualidade do solo (D'ANDRÉA et al., 2002).

Para Klein et al. (2010), os principais fatores que influenciam na retenção e disponibilidade de água às plantas são a textura e a estrutura do solo. A qualidade estrutural do solo tem sido comumente analisada por parâmetros como a densidade e a porosidade. Essas propriedades são de fácil determinação e possibilitam a verificação do efeito de sistemas de manejo sobre a estrutura do solo (DALBIANCO, 2009).

A classe textural do solo está relacionada com a proporção de tamanho das suas partículas minerais (KLEIN et al., 2010). Esta pode ser analisada por meio da análise granulométrica, que permite classificar os componentes sólidos de acordo com o seu diâmetro em areia, silte e argila (KIEHL, 1979).

A textura constitui-se de uma das características mais estáveis do solo (VIEIRA; MELLO; LIMA, 2007), sendo sua variabilidade decorrente da variação natural deste

(OLIVEIRA JÚNIOR; SOUZA; MELO, 2010). Isso faz com que a textura seja considerada um elemento de grande importância na tomada de decisão, na identificação e na classificação do solo (EGUCHI; SILVA; OLIVEIRA, 2002).

A compactação do solo também consiste em um problema que influencia diretamente o desenvolvimento das culturas, sendo que, para Queiroz-Voltan, Nogueira e Miranda (2000), em solos compactados, as raízes das plantas não se beneficiam adequadamente dos nutrientes disponíveis, uma vez que o desenvolvimento de novas raízes, responsáveis pela absorção de água e nutrientes, fica prejudicado.

Para Silva Júnior et al. (2012), o mapeamento de atributos físicos do solo juntamente com o levantamento topográfico das lavouras pode ser uma das soluções para caracterização detalhada dos solos em estudos de adoção de AP e implementação de estratégias adequadas de manejo.

Segundo Mendes, Fontes e Oliveira (2008), os atributos físicos do solo variam entre pontos relativamente próximos, muitas vezes de forma significativa. Assim, o uso da geoestatística permite que a estrutura de dependência espacial seja modelada e visualizada espacialmente, possibilitando indicar alternativas de manejo adequadas frente à variabilidade espacial das suas características físicas sobre o desenvolvimento das plantas.

3.2.2 Atributos químicos do solo

O solo, como um sistema trifásico (sólido, líquido e gasoso) com diferentes constituintes em sua fase sólida, apresenta um alto número de elementos químicos (REICHERT; SANTOS, 2009). Um elemento é considerado essencial quando ele participa de algum composto ou reação sem o qual a planta não completa seu ciclo de vida (MALAVOLTA; VITTI; OLIVEIRA, 1997).

Os elementos essenciais, também chamados de nutrientes, são classificados, em função da quantidade em que são absorvidos pelas plantas, em dois grupos: os macronutrientes e os micronutrientes. Os macronutrientes são os de que as plantas necessitam em maior quantidade – Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg) e Enxofre (S). Já os micronutrientes – Boro (B), Cloro (Cl), Cobre (Cu), Ferro (Fe), Manganês (Mn), Molibdênio (Mo) e Zinco (Zn) – são exigidos em menor quantidade pelas plantas (LIMA, 2010).

O pH do solo, propriedade correlacionada com a acidez, é um importante indicador das suas condições químicas, pois interfere na disponibilização de vários elementos químicos (BRANDÃO; LIMA, 2002).

A matéria orgânica é originária de plantas, minerais e microorganismos que habitam o solo. Segundo Figueiredo, Ramos e Tostes (2008), a sua importância no solo é abrangente. Sua atuação se dá tanto na melhoria das condições físicas, como na aeração,

na maior retenção e no armazenamento de água, quanto nas propriedades físico-químicas, no fornecimento de nutrientes às plantas e na maior capacidade de troca catiônica do solo. Além disso, ela proporciona um ambiente adequado ao estabelecimento e à atividade da microbiota.

É importante avaliar as propriedades químicas do solo para determinar a sua capacidade de reter nutrientes e disponibilizá-los às raízes e controlar a disponibilidade de elementos tóxicos às plantas. Com essas informações, é possível manejar adequadamente e de modo mais eficiente a aplicação de corretivos e fertilizantes (REICHERT; SILVA; SANTOS, 2009), melhorando o gerenciamento dos sistemas de produção e reduzindo os custos e a degradação ambiental provocada pelo excesso desses nutrientes (ROCHA; LAMPARELLI, 1998).

A análise dos dados por meio dos mapas temáticos dos atributos químicos possibilita a distinção de regiões com menor e maior variabilidade desses atributos, o que permite manejá-los de forma diferenciada e localizada (LIMA; OLIVEIRA; SILVA, 2008).

3.3 Agricultura de precisão

Com o início da produção agrícola em grande escala, as lavouras passaram a ser tratadas de maneira uniforme, sendo as taxas de aplicação de fertilizantes calculadas baseando-se em valores médios de fertilidade e a aplicação realizada uniformemente em todo o talhão (SILVA et al., 2008). Com isso, certas regiões podem receber superdosagens enquanto outras recebem uma quantidade aquém da necessária, não sendo corrigidas de forma adequada (TIEPPO et al., 2007).

Os elevados níveis de produtividade estão associados ao intenso uso de insumos. Diante disso, há a necessidade de se desenvolverem sistemas que permitam racionalizar o uso de insumos e, conseqüentemente, os custos de produção e o impacto ambiental, ao mesmo tempo em que se incrementa a produção (MOLIN; RABELLO, 2011; BOTTEGA et al., 2013).

Por ser o solo um sistema heterogêneo, o conhecimento detalhado da variabilidade espacial dos seus atributos pode otimizar a aplicação de insumos, de forma localizada, melhorando o controle dos sistemas de produção (CAVALCANTE et al., 2007).

Para Dobermann e Ping (2004), a agricultura de precisão (AP) tem como principal objetivo aplicar as quantidades de insumos necessárias, no local correto e no momento adequado. Nesse contexto, a AP apresenta-se como um conjunto de tecnologias para auxiliar o produtor no gerenciamento da variabilidade das lavouras e na adoção de melhores estratégias de manejo, com vistas a aumentar a eficiência da produção e reduzir os custos de aplicação de insumos, tornando a atividade mais competitiva (AMADO et al., 2006; FERRAZ et al., 2012).

Grande parte do ciclo operacional da AP utiliza tecnologias desenvolvidas por outras áreas e adaptadas ao meio agrícola, como o GPS (Global Positioning System), a informática, por meio dos computadores e programas aplicados, e grande parte dos sensores e controladores utilizados nas máquinas agrícolas (MOLIN, 2003).

Apesar dos benefícios da AP no gerenciamento da produção agrícola, esse sistema de gestão demanda um elevado número de dados para que se possa determinar a variabilidade e obter resultados desejáveis (TSCHIEDEL; FERREIRA, 2002), além do uso de equipamentos sofisticados para correção dos atributos que interferem na produção.

Segundo Yan et al. (2007), o custo de obtenção de amostras de solo para caracterizar a variabilidade de campo é um dos principais problemas na agricultura de precisão. Para Khosla (2010), ainda é necessária uma técnica economicamente viável para quantificar a variabilidade espacial das propriedades do solo e da cultura, já que a AP deve desempenhar um papel importante também nas propriedades de pequeno porte e atender as necessidades dos agricultores em diferentes condições no mundo.

3.4 Geoestatística

Segundo Molin et al. (2007), quando uma propriedade do solo ou da planta varia espacialmente com alguma organização, expressa pela dependência espacial, é possível aplicar a geoestatística.

O estudo detalhado da variabilidade espacial dos fatores que interferem na produtividade, por meio da geoestatística, pode aperfeiçoar a aplicação localizada de insumos, melhorando assim o controle dos sistemas de produção (CAVALCANTE et al., 2007).

A geoestatística oferece técnicas para elaboração de mapas de comportamento de variáveis georreferenciadas, utilizando um método de interpolação de informações (krigagem) a partir de dados obtidos em locais amostrados e modelados em um semivariograma experimental (FARACO et al., 2008).

O semivariograma é o instrumento que permite determinar o grau de dependência espacial entre amostras, considerando que pontos amostrais mais próximos tendem a possuir maior similaridade do que pontos mais distantes, podendo-se determinar ainda a distância em que as amostras passam a se tornar independentes (SANTOS et al., 2011).

Para Faraco et al. (2008), o principal estimador utilizado na construção do semivariograma experimental é o estimador clássico de Matheron. Para o caso de não haver distribuição normal dos dados, é recomendado o estimador de Cressie e Hawkins, que é menos tendencioso para esse tipo de dados (FARACO et al., 2008).

Para Isaaks e Srivastava (1989), são três os principais parâmetros na determinação de um modelo geoestatístico: o alcance, que corresponde à distância a partir da qual as

amostras passam a ser independentes; o patamar, que é o valor de variância ao ponto em que o semivariograma se estabiliza, sendo que a partir desse ponto considera-se que não existe mais dependência espacial entre as amostras, porque a variância entre os pares de amostras torna-se invariável com a distância; e o efeito pepita, em que quando a distância entre dois pontos diminui gradativamente tendendo a zero, ocorre a aproximação de um valor positivo que revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras.

O semivariograma experimental pode assumir diversas formas em função dos dados e do intervalo de amostragem. Por esse motivo, Isaaks e Srivastava (1989) afirmam que é necessário ajustar uma função para esses pontos. Segundo Cressie (1993), o modelo a ser selecionado deve representar da melhor forma a distribuição das semivariâncias. Por isso, podem ser ajustados modelos distintos, sendo os principais os modelos esférico, exponencial e gaussiano.

É necessário avaliar qual dos modelos teóricos melhor se ajusta aos dados obtidos nas amostras. Para Isaaks e Srivastava (1989), a validação cruzada é mais indicada na avaliação do melhor modelo para o semivariograma, sendo que esta consiste em uma avaliação de erros de estimativa que permite comparar valores estimados e amostrados, usando-se somente a informação disponível na amostra de dados.

3.5 Métodos de interpolação

Os métodos de interpolação permitem estimar o valor de um atributo em locais não amostrados, a partir de pontos coletados na mesma área ou região (JAKOB; YOUNG, 2006; MOLIN, 2003). A interpolação espacial converte dados pontuais em campos contínuos, produzindo padrões espaciais que podem ser comparados com outras entidades espaciais contínuas (JAKOB; YOUNG, 2006). Segundo Miranda (2010), a ideia base da interpolação é que, em média, valores do atributo tendem a ser semelhantes em locais mais próximos do que em locais mais afastados.

Para Bazzi et al. (2010), a interpolação de dados é requisito para a construção de mapas temáticos, sendo que é importante a avaliação da qualidade dos interpoladores e o mapa interpolado deve representar da melhor forma possível a realidade da distribuição do atributo estudado.

Diversos métodos de interpolação, com diferentes níveis de complexidade, estão disponíveis na literatura (CARVALHO; SILVEIRA; VIEIRA, 2002). Os métodos de interpolação mais utilizados em AP são o inverso da distância elevado a uma potência (IDP) e a krigagem. A diferença entre eles é a maneira como os pesos são atribuídos às diferentes amostras (MIRANDA; FREITAS; FAGGION, 2009).

No interpolador IDP, os pesos são definidos como o inverso da distância elevado a uma potência, em que a distância é a que separa o valor interpolado dos valores observados, tal que a influência de cada ponto amostrado é inversamente proporcional à distância do ponto a ser estimado (ALVES; VECCHIA, 2011).

Esse método possui dois casos mais conhecidos: o inverso da distância (ID) e o inverso da distância ao quadrado (IDQ). A diferença entre eles é o expoente ao qual o cálculo é submetido. A potência é utilizada para atenuar a influência dos pontos distantes. É um processo matemático no qual os dados são ponderados de tal forma que a influência entre eles diminui conforme aumenta a distância. O fator peso é predeterminado pelo valor da potência escolhida, sendo que, quanto maior a potência, menor é a influência dos pontos mais distantes por ela proporcionada (MAZZINI; SCHETTINI, 2009).

Uma das desvantagens do IDP é a geração do “efeito mira” ao redor dos pontos observados (ALVES; VECCHIA, 2011). Porém, esse método também apresenta acurácia satisfatória, além de exigir uma análise mais simples, o que pode tornar o processo menos oneroso, e, em alguns casos, proporciona resultados semelhantes à krigagem (SOUZA et al., 2010a).

A krigagem utiliza a geoestatística para realizar a interpolação, fato que para Alves e Vecchia (2011) o torna vantajoso sobre outros métodos. Esse método utiliza a dependência espacial entre as amostras, expressa pelo semivariograma, para estimar valores em qualquer posição dentro do talhão (CARVALHO; ASSAD, 2005).

Dos métodos geoestatísticos de estimativa existentes, o mais difundido é a krigagem ordinária. Sua utilização resulta em valores com mínima variância de erro, o que proporciona precisão local, porém estas estimativas são suavizadas fazendo com que os valores máximos da distribuição estatística dos dados tendam a ser subestimados e os valores mínimos sejam superestimados (ROCHA; LOURENCO; LEITE, 2007).

Para Kravchenko e Bullock (1999), a ponderação IDP é mais fácil de ser aplicada, além de ser um método rápido e que requer pouco custo computacional (MAZZINI; SCHETTINI, 2009), enquanto que a krigagem consome mais tempo e sua aplicação é mais complexa (MOLIN, 2003). Por outro lado, a krigagem faz uma descrição mais acurada da estrutura espacial dos dados e produz informação sobre a distribuição da estimativa do erro (ANGELICO, 2006).

A krigagem depende de modelos matemáticos e estatísticos, assim como noções de autocorrelação (JAKOB; YOUNG, 2006), além de conhecimento aprofundado em geoestatística (NEGREIROS et al., 2010; ANDRIOTTI, 2002). Acrescenta-se, ainda, que a quantidade de amostras deve gerar um número mínimo de 30 pares para cada distância em estudo (CRESSIE, 1993), o que resulta em valores interpolados aproximados ou correlacionados ao ponto do campo mais próximo (MOLIN, 2003; ANDRIOTTI, 2002).

Em estudos que comparam os métodos de interpolação na geração de mapas temáticos, vários autores obtiveram melhores resultados no uso da krigagem em comparação com o IDP (MELLO et al., 2003; CARVALHO; ASSAD, 2005; SILVA et al., 2008; GARDIMAN JUNIOR, et al., 2012; SOUZA et al., 2010a). Entretanto, existem trabalhos que demonstram ser o IDP mais ou tão eficiente quanto a krigagem (ALVES; VECCHIA, 2011; COELHO et al., 2009).

3.6 Unidades de manejo

Um dos problemas chave da AP é a necessidade de uma grade amostral densa, a fim de se detectar a variabilidade espacial do atributo em estudo e possibilitar a geração de mapas que representem de maneira real o talhão (RODRIGUES JUNIOR et al., 2011). Regiões que dentro do talhão possuem características semelhantes, necessitando da mesma quantidade de insumo, e resultam do mesmo potencial produtivo podem ser denominadas UM (SCHEPERS et al., 2004).

A definição de UM torna mais fácil a aplicação das técnicas de AP, uma vez que é possível empregar, no manejo das culturas, os mesmos sistemas utilizados na agricultura convencional (RODRIGUES JUNIOR et al., 2011).

Para Rodrigues e Zimback (2002), a definição de UM é uma alternativa para viabilizar economicamente a AP, pois atuam como unidades de gerenciamento na aplicação localizada de insumos e como indicadores para amostragem de solo e da cultura. Segundo Yan et al. (2007), o conhecimento das UM pode permitir uma redução no número de análises de solo necessário para criar mapas de aplicação para as operações de cultivo.

Apesar de haver a possibilidade de utilizar-se qualquer atributo que possa estar relacionado à produtividade da cultura, para Doerge (2000), o ideal é que se utilizem fontes de informação espacial estáveis e previsíveis ao longo do tempo e que estas estejam correlacionadas com a produtividade.

Nesse sentido, vários pesquisadores encontraram resultados positivos trabalhando com a definição de UM em diferentes culturas e com diferentes parâmetros. Este é o caso de Ortega e Santibáñez (2007), que trabalharam com dados de fertilidade do solo na cultura do milho; Fleming e Westfall (2000), com a experiência do produtor na cultura da soja; Milani et al. (2006), com dados de produtividade da cultura da soja; e Fraisse, Sudduth e Kitchen (2001), com atributos topográficos do solo e a condutividade elétrica no cultivo de milho, soja e sorgo.

3.7 Métodos para geração de unidades de manejo

Existem várias técnicas de definição de UM disponíveis na literatura (HORNUNG et al., 2006). Xiang (2007) realizou a divisão entre técnicas a partir das formas de abordagem. A primeira forma corresponde aos métodos empíricos, que utilizam a distribuição da produtividade e o conhecimento especializado para dividir o talhão. Tais métodos são considerados mais simples, mas estão sujeitos a decisões subjetivas (FRAISSE; SUDDUTH; KITCHEN, 2001). A segunda corresponde ao método de análise de agrupamento, como os algoritmos K-Means e Fuzzy C-Means, que são considerados mais complexos e permitem um maior grau de diferenciação entre classes.

Os algoritmos de agrupamento têm o objetivo de particionar um conjunto de dados em k -clusters, tendo como referência um centro de massa ou centroide para cada cluster formado (LUZ, 2004).

O algoritmo de classificação K-Means tem a finalidade de agrupar objetos de atributos em K grupos, bem como minimizar a soma dos quadrados das distâncias entre dados e os centroides correspondentes a cada agrupamento. O algoritmo funciona de maneira iterativa, com a finalidade de adicionar o centroide de cada agrupamento o mais próximo possível dos dados a serem agrupados.

A lógica Fuzzy aproxima uma função por associações linguísticas de entrada e saída de dados e aplica regras Fuzzy para a teoria dos conjuntos, com o objetivo de resolver problemas que uma teoria mais rígida teria dificuldade de modelar. Ela tem a intenção de fornecer um tratamento matemático a certos termos linguísticos subjetivos, tais como “aproximadamente”, “dentre outros” e “em torno” (BARROS; BASSANEZI, 2010).

Técnicas de análise de agrupamento de dados foram utilizadas na delimitação de UM por Rodrigues Junior et al. (2011); Taylor et al. (2003); Santos et al. (2003); Yan et al. (2007) e Reyniers et al. (2006).

Taylor et al. (2003) fizeram uso do algoritmo K-Means para definir UM por meio de dados de produtividade e indução eletromagnética do solo e concluíram que tais UM coincidem com diferenças nutricionais do solo.

Reyniers et al. (2006) utilizaram dados de elevação e declividade do solo e a produtividade da cultura do trigo para definir UM por meio do algoritmo K-Means e concluíram que o uso das UM pode otimizar a produção e a aplicação de insumos, além de diminuir os impactos ambientais negativos.

Yan et al. (2007), utilizando o algoritmo de agrupamento Fuzzy C-Means na geração de UM para a caracterização das propriedades químicas do solo, concluíram que as UM geradas se mostraram eficientes no conhecimento da variabilidade da produtividade e no desenvolvimento de um plano de amostragem de solo direcionada.

Os algoritmos K-Means e Fuzzy C-Means se diferenciam em razão da robustez incorporada ao método Fuzzy C-Means, por Zadeh (1965), que introduziu a teoria da lógica Fuzzy ao algoritmo de divisão, aprimorado por Ruspini (1969). Estatisticamente, a técnica Fuzzy C-Means minimiza a soma dos quadrados dos erros dentro de cada classe. Segundo Venturieri (1996), os dados são agrupados de forma iterativa para a classe mais próxima a partir do critério da mínima distância. O método Fuzzy C-Means busca a minimização da variância intraclases e a maximização da variância interclasses (RODRIGUES JUNIOR et al., 2011).

Segundo Santos, Saraiva e Molin (2012), o algoritmo Fuzzy C-Means apresenta melhor desempenho que o K-Means. Já para Jipkate e Gohokar (2012) e Shrivastava et al. (2010), os dois apresentam resultados satisfatórios, porém o K-Means se destaca por requerer menos tempo de computação. Alguns autores também concluíram que os dois métodos de agrupamento não apresentaram diferenças (RODRIGUES JUNIOR et al., 2011; BORGES, 2010).

3.8 Avaliação de unidades de manejo

Após a delimitação das UM, é importante que seja realizada a sua avaliação a fim de se verificar se a delimitação representa diferença significativa no potencial produtivo da cultura, ou seja, se cada uma delas pode ser tratada como unidade de gerenciamento isolada do restante do talhão e assim servir como fonte de recomendação e análise para atributos químicos e físicos (BAZZI, 2011).

Dobermann et al. (2003) comentam que, entre as técnicas de avaliação do desempenho da geração de UM, se destaca o método proposto por Webster e Oliver (1990), referente à redução da variância e a análise de variância (Bazzi et al., 2013), sendo que para essa análise as amostras são consideradas como independentes dentro de cada UM.

Xiang (2007) afirma que, com o aumento da quantidade de UM, a variância relativa tende a diminuir até um momento em que se estabiliza. Tal fato pode auxiliar na determinação do número mínimo de UM a serem utilizadas.

3.9 Comparação de mapas temáticos

Os mapas temáticos exibem padrões espaciais de um atributo ou de um conjunto deles. Nesse tipo de mapa, a localização é algo muito importante para referenciar onde o fenômeno ocorreu (SPERANZA, 2008). Conforme Câmara (1995), os mapas temáticos representam dados espaciais e se caracterizam por conter regiões definidas por um ou mais polígonos.

Os mapas de distribuição espacial são gerados a partir de modelagem matemática ou estatística, por meio dos métodos de interpolação, ou seja, estimam-se valores para locais não amostrados, a partir de um determinado número de pontos observados em campo. No entanto, é necessário comparar os métodos de interpolação, pois os resultados obtidos na geração dos mapas poderão ser diferentes dependendo do método utilizado (TIEPPO et al., 2007).

Segundo Figueiredo e Vieira (2007), a exatidão de um mapa indica a proximidade de uma determinada medida ao seu valor real, então, a confiabilidade de um mapa está vinculada a sua exatidão. Nesse sentido, a qualidade da estimativa depende tanto da escolha dos métodos de interpolação, como também da aplicação apropriada de métodos indicados para as características dos dados em estudo.

Para Antunes e Lingnau (1997), a avaliação da acurácia de mapas temáticos pode ser obtida por meio de coeficientes de concordância, tais como os índices Kappa e Tau (SANO; SANTOS; MENESES, 2009). São métodos qualitativos em que os valores obtidos por meio da interpolação dos dados necessitam ser reclassificados em classes iguais. Para tal, os valores são computados em uma matriz de erros e todos os elementos dessa matriz são considerados para se obter o índice desejado (SANO; SANTOS; MENESES, 2009).

O índice Kappa é uma medida estatística que foi introduzida por psicólogos e adaptada como medida de concordância para mapas por Congalton e Green (1993). Segundo Cohen (1960), o índice Kappa é um coeficiente de concordância para escalas nominais que mede a proporção de concordância depois que a concordância atribuída à casualidade é retirada. Esse método testa a associação entre mapas e ajuda a entender se os mapas diferem devido a alguma variação casual ou se há uma real concordância (MILANI et al., 2006).

A análise do coeficiente Kappa é uma técnica utilizada para calcular a medida de concordância global que envolve a matriz de erro completa, incluindo informações de erro por omissão e de erro por inclusão. Baseia-se na diferença entre a concordância real de classificação (presente na diagonal principal) e a probabilidade de concordância (concordância por puro acaso). A concordância por puro acaso é dada pelo produto dos valores das linhas e colunas marginais (AMORIN, 2009).

Foody (1992) ressaltou que o grau de concordância por chance poderia estar sendo superestimado, pelo fato de incluir também a concordância real, e que por conta disso a magnitude do Kappa não refletiria a concordância presente na classificação, apenas descontando a casualidade. Devido a isso, foi criado o índice Tau para a medição da precisão de classificação, definido por Ma e Redmond (1995). Na formulação do coeficiente Tau, o valor da concordância casual é estabelecido, de modo a serem evitadas as falhas que ocorrem em outros métodos de comparação como o da exatidão global e o coeficiente Kappa (PONZONI; REZENDE, 2002).

Para Figueiredo e Vieira (2007), os coeficientes de concordância Kappa e Tau apresentam valores aproximados e ao se realizar uma avaliação da acurácia de mapas temáticos ambos podem ser recomendados. Os mesmos resultados foram encontrados por Brites, Soares e Ribeiro (1996) em seus estudos na comparação de índices de concordância.

4 MATERIAL E MÉTODOS

4.1 Áreas experimentais

Para este estudo foram utilizadas duas áreas experimentais, sendo delimitados e determinados os pontos amostrais com auxílio de um aparelho receptor GPS topográfico Trimble Geo Explorer XT 2005 e o software PathFinder.

A primeira área experimental (chamada de área 1) possui cerca de 15,5 ha (Figura 1) e está localizada no município de Céu Azul, PR, com localização geográfica central aproximada de 25°06'32" S e 53°49'55" O e altitude média de 752 m. O solo é classificado como LATOSSOLO VERMELHO Distroférico típico (EMBRAPA, 2006) e cultivado em um sistema de plantio direto há mais de 10 anos, com sequência de culturas soja, trigo, milho e aveia para fins comerciais.




Figura 1 Localização da área 1
Fonte: Google Earth (2012)

Os dados meteorológicos de precipitação, temperatura máxima, temperatura mínima e umidade média relativa do ar mensais dos períodos analisados (safra da soja 2011/2012 e 2012/2013) (Figura 2) foram disponibilizados pelo Instituto Tecnológico Simepar, procedidos da estação meteorológica localizada no município de Cascavel, PR, por ser a estação mais próxima da área em estudo.

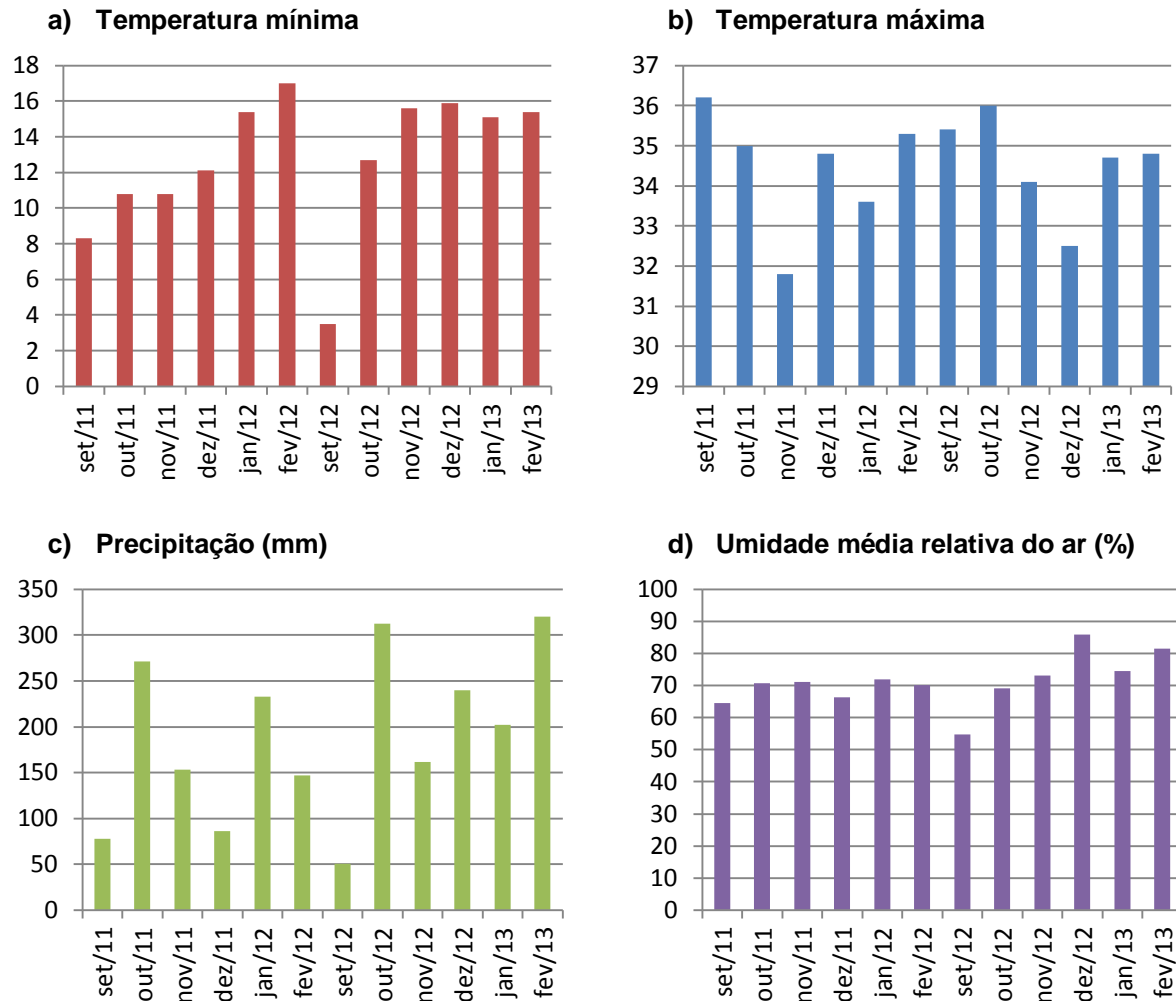


Figura 1 Variação mensal de temperatura mínima, temperatura máxima, precipitação e umidade média relativa do ar nos períodos de safra 2011/2012 e 2012/2013 para a região de Cascavel, PR

Fonte: Instituto Tecnológico Simepar (2013)

A segunda área (chamada de área 2) possui cerca de 9,9 ha (Figura 3) e está localizada no município de Serranópolis do Iguçu, PR, sob coordenadas geográficas centrais aproximadas de 25°24'28" S e 54°00'17" O e com altitude média de 355 m. O solo é classificado como LATOSSOLO VERMELHO Distroférico típico (EMBRAPA, 2006) e é cultivado sob sistema de plantio direto há pelo menos 10 anos com sucessão de culturas soja e milho para fins comerciais.



Figura 3 Localização da área 2
Fonte: Google Earth (2012)

Os dados meteorológicos de precipitação, temperatura máxima, temperatura mínima e umidade relativa do ar mensais dos períodos analisados (safra da soja 2012/2013 e milho safrinha 2013) (Figura 4) para área 2 também foram disponibilizados pelo Instituto Tecnológico Simepar, procedidos da estação meteorológica localizada no município de São Miguel do Guaçu, PR, por ser a estação mais próxima da área em estudo.

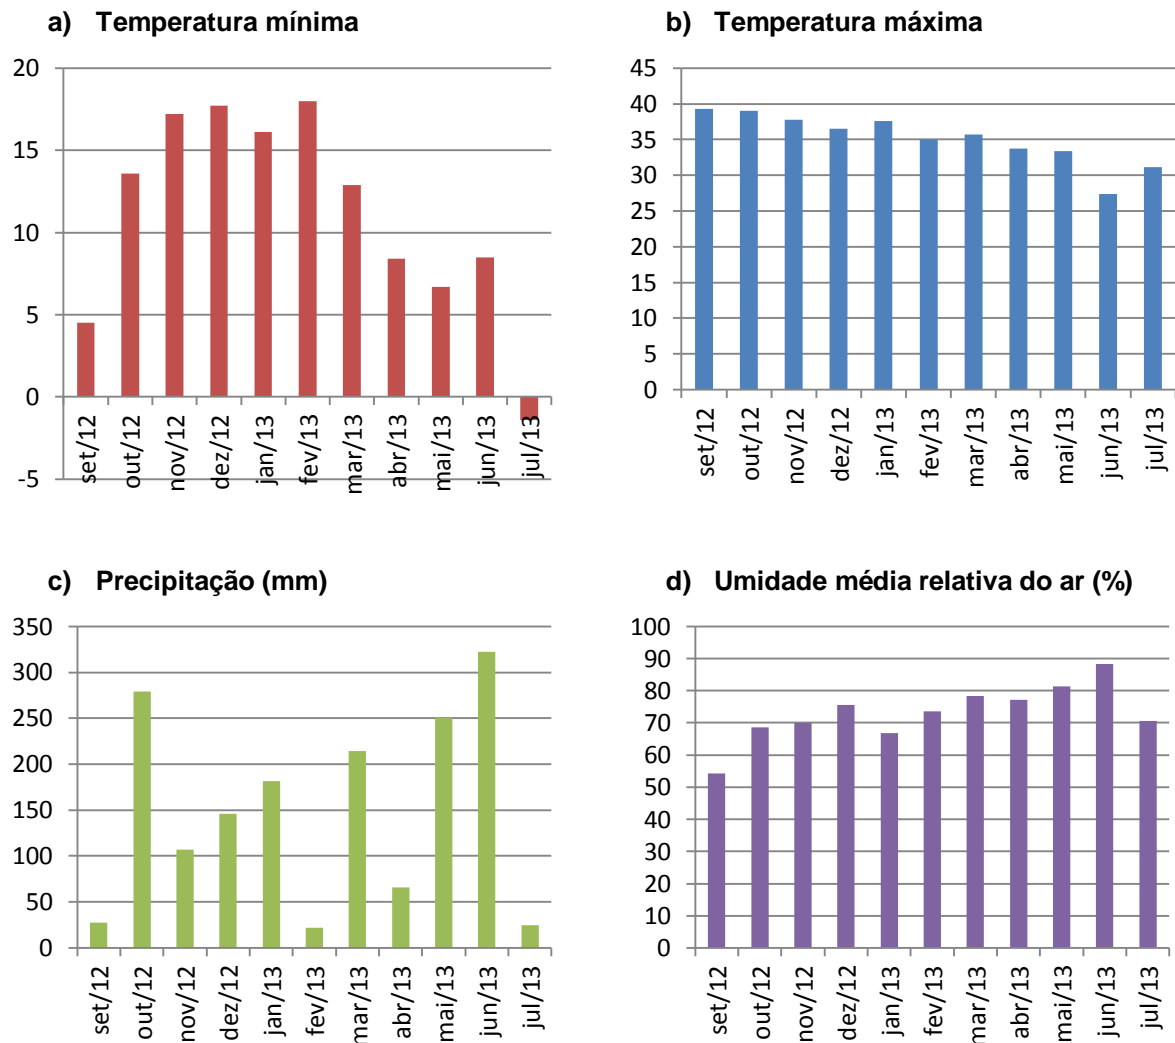


Figura 4 Variação mensal de temperatura mínima, temperatura máxima, precipitação e umidade média relativa do ar dos períodos de safra da soja 2012/2013 e milho safrinha 2013 para a região de São Miguel do Iguaçu, PR
Fonte: Instituto Tecnológico Simepar (2013)

4.2 Grades amostrais

Tendo em vista que ambas as áreas possuem considerável grau de declividade e apresentam curvas de nível, foram utilizadas grades amostrais irregulares, sendo determinados os pontos em locais que não coincidiram com as curvas de nível, visando à influência direta destas com a produtividade, principalmente devido às condições físicas do solo e o acúmulo de água nesses locais.

Foram definidos 40 pontos amostrais ($2,58 \text{ ha}^{-1}$) para área 1 (Figura 5) e 42 pontos amostrais ($4,24 \text{ pontos ha}^{-1}$) para área 2 (Figura 6), sendo para cada ponto, determinados os atributos físicos e químicos do solo e a produtividade das culturas. Como foi realizada a interpolação por krigagem, optou-se por um mínimo de 40 pontos amostrais, com vistas a

atender o critério de um mínimo de 30 pares para cada ponto do semivariograma (CRESSIE, 1993).

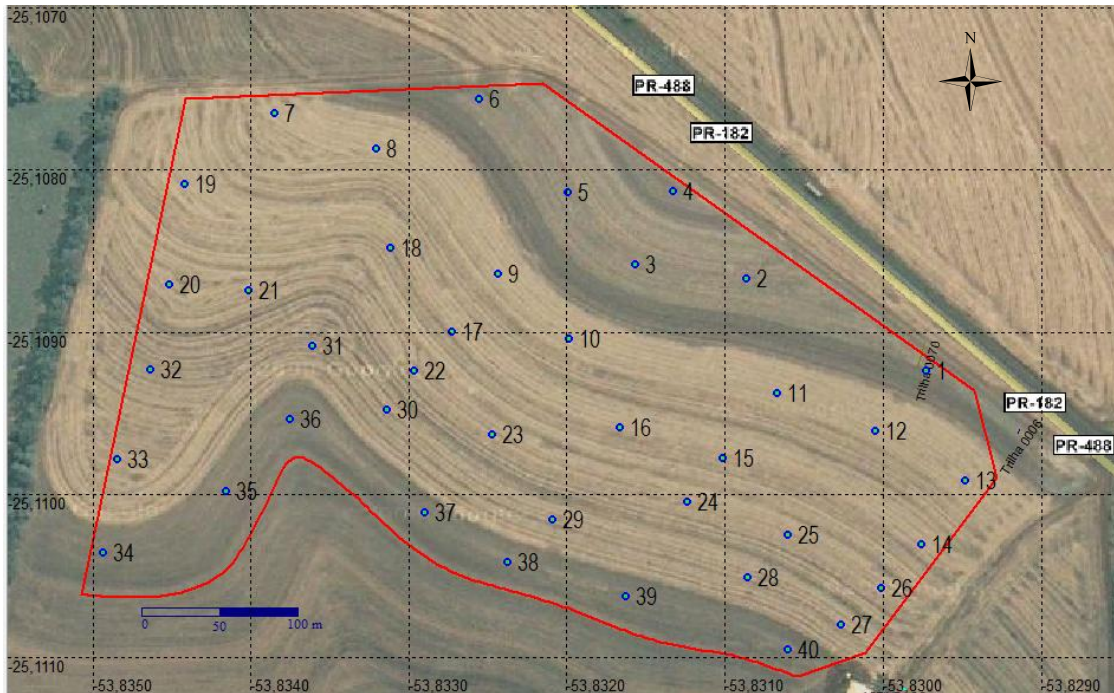


Figura 5 Grade amostral utilizada para determinação das características físicas e químicas do solo na área 1
Fonte: Google Earth (2012)

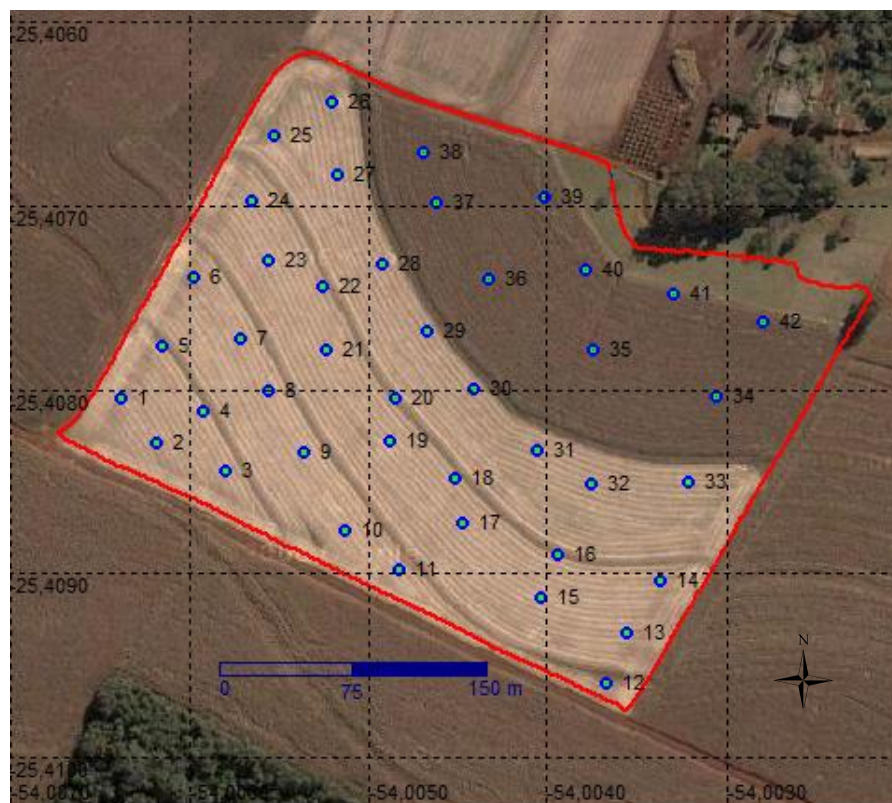


Figura 6 Grade amostral utilizada para determinação das características físicas e químicas do solo e produtividade das culturas na área 2
Fonte: Google Earth (2012)

4.3 Atributos químicos e físicos do solo

Em cada ponto amostral, foram determinados os atributos relativos a altitude, declividade, atributos químicos (Al, C, pH, $H+Al^3$, Ca, P, Mg, K, Cu, Zn, Fe, Mn), textura (argila, silte e areia), resistência mecânica do solo à penetração além da densidade, macro e microporosidade e porosidade total. Os valores de V%, soma de bases, M%, matéria orgânica e CTC foram calculados por meio da utilização de equações clássicas (EMBRAPA, 1997).

A amostragem de solo foi realizada com auxílio de um trado, na profundidade de 0-20 cm, sendo que para cada um dos pontos amostrais foram coletadas oito subamostras, coletadas em um raio de 3 m do ponto determinado pela grade amostral (adaptado de WOLLENHAUPT; WOLKONSKI; CLAYTON, 1994). O solo foi acondicionado em sacos destinados para esse fim e encaminhados para análise laboratorial, onde foram definidos os atributos químicos, a matéria orgânica e a característica textural.

A resistência do solo à penetração foi determinada utilizando-se um penetrômetro eletrônico da marca Falker PenetroLOG, com o qual foram realizadas quatro medições no entorno do ponto definido na grade amostral (a distância máxima de 3 m), calculando-se posteriormente a média das medições para representação do ponto, nas profundidades de 0-0,1, 0-0,2, 0,1-0,2 e 0,2-0,3 m.

Utilizando anel volumétrico, foram coletadas amostras de solo não deformadas, com vistas a determinar teor de água, densidade do solo, macroporosidade, microporosidade e porosidade total. Para a determinação da porosidade (porosidade total, macro e microporosidade), as amostras de solo não deformadas foram saturadas por 24 h em bandeja com água até dois terços da altura do anel. Após o período de saturação, as amostras foram drenadas no potencial equivalente a 0,006 MPa utilizando-se mesa de tensão. Ainda com as amostras, foi determinada a densidade aparente do solo, por meio do método do volume conhecido e teor de água do solo obtido com a mesa de tensão (EMBRAPA, 1997).

A altitude foi obtida por meio de estação total eletrônica Topcon GPT-7505, sendo posteriormente calculada a declividade em função da altitude de cada ponto amostral, utilizando o software Surfer 10.

4.4 Adubação e culturas

Para realização desta pesquisa, foram analisadas duas safras de soja (anos agrícolas 2011/2012 e 2012/2013) na área 1. Na área 2, foram analisadas as culturas de soja (ano agrícola 2012/2013) e milho safrinha (ano agrícola 2013).

Na área 1, a safra da soja 2011/2012 foi semeada em 04 de novembro de 2011 a cultivar de soja Nindera 4990, com 45 cm de espaçamento entre linhas. Juntamente com a semeadura, foi realizada adubação na linha com NPK e aplicados a lanço em taxa variável de 69 a 104 kg ha⁻¹ de KCL. Na safra da soja 2012/2013, foi semeada em 08 de outubro a cultivar de soja Vtop da Syngenta, com espaçamento de 45 cm entre linhas. Juntamente com a semeadura, foi realizada adubação com 200 kg ha⁻¹ de MAP e 200 kg ha⁻¹ de calcário de concha e aplicados a lanço KCL a taxa variável.

Na área 2, foi utilizada a cultivar de soja CD 202 da Coodetec, com espaçamento de 50 cm entre linhas, semeada em 17 de setembro de 2012. Na linha da semeadura, foi realizada adubação com 200 kg ha⁻¹ de N-P-K com formulação 01-28-00 e foram aplicados a lanço 103 kg ha⁻¹ de Cloreto de Potássio e 21 kg ha⁻¹ de Enxofre.

Nessa área, foi semeado em 01 de fevereiro de 2013 o híbrido de milho AG 9010 da Agrocere, com espaçamento entre linhas de 50 cm. Na linha da semeadura, foi realizada adubação com 200 kg ha⁻¹ de N-P-K formulação 13-06-09 e após 20 dias da semeadura foi aplicado 200 kg ha⁻¹ adubo de cobertura Sulfammo com formulação 46-00-00.

4.5 Mapeamento da produtividade

Na área 1, a produtividade da soja foi medida com monitor de colheita acoplado em uma colhedora da marca CASE IV. Na área 2, em cada ponto amostral a produtividade tanto da soja quanto do milho foi determinada de forma manual.

4.5.1 Filtragem de dados da colhedora

O arquivo proveniente do monitor de colheita foi convertido, por meio do programa AFS CASE, a fim de que os dados pudessem ser trabalhados facilmente no formato texto.

Para eliminar a presença de dados inconsistentes e conseqüentemente prejudiciais à qualidade do mapa gerado, foi aplicado um procedimento para eliminação desses possíveis erros de amostragem (Figura 7).

O primeiro passo foi retirar do arquivo de produtividade erros grosseiros de posicionamento, representados por pontos localizados fora do talhão, causados por falha do receptor GPS ou mesmo falha do operador em baixar a plataforma da colhedora fora da área de colheita. Na segunda etapa, retiraram-se os dados coletados com largura de

plataforma parcial, ou seja, diferente da largura máxima informada ao sistema. Na terceira etapa, foram retirados pontos com distância nula.

A quarta etapa compreendeu uma análise exploratória dos dados em busca de valores discrepantes do conjunto. Para isso, foi aplicado o algoritmo proposto por Gimenez e Molin (2004), que trabalha os dados de produtividade um a um, comparando-os com a média de todos os dados e eliminando pontos que apresentam valor de produtividade duas vezes superior e inferior à média de todos os pontos, corrigindo possíveis falhas do sensor de produtividade.

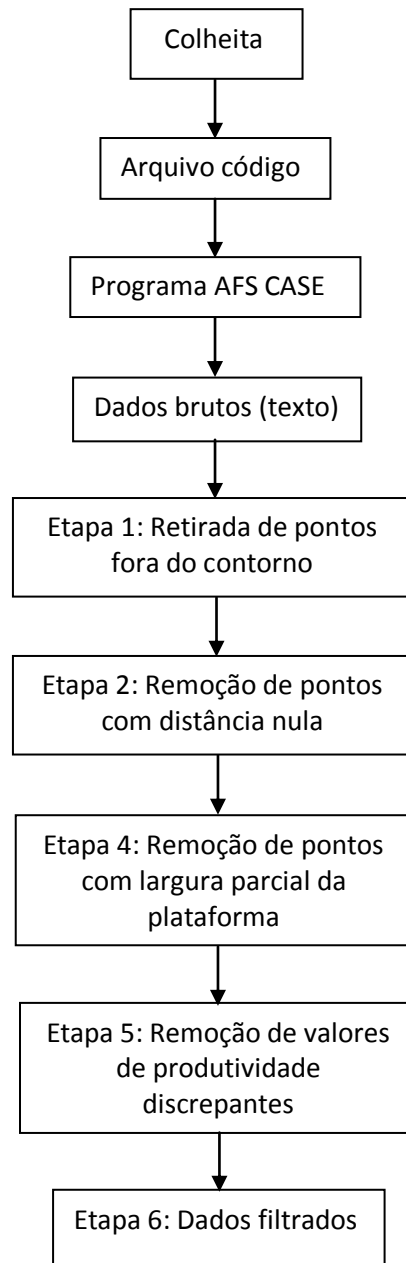


Figura 7 Procedimento de filtragem dos dados brutos da colhedora

4.5.2 Determinação manual da produtividade

Para determinação da produtividade na área 2, com o auxílio de um instrumento de corte do tipo foice foram cortadas manualmente as plantas de duas linhas de semeadura em 1 m linear cada, sendo cada ponto então representado por uma área de aproximadamente 0,9 m².

As plantas foram acomodadas em sacos (tipo ráfia) e posteriormente foi realizada a triagem manual e limpeza. Em seguida, os grãos foram pesados e para cada amostra foram separadas duas repetições de 5 g cada, que foram secadas de acordo com o método de secagem em estufa a 105° C durante 24 h, para posterior correção da produtividade para o grau de 13% de umidade, de acordo com as regras de Análise de Sementes (MAPA, 2009).

A porcentagem de umidade foi calculada na base da massa inicial, aplicando-se a Equação 1:

$$\text{Umidade}(\%) = 100 * \left(\frac{M_i - M_f}{M_i} \right) \quad \text{Eq. (1)}$$

em que:

M_i – massa inicial, que corresponde ao peso da semente úmida;

M_f – massa final, que corresponde ao peso da semente seca.

Depois de realizada a secagem, a massa final das amostras foi calculada pela Equação 2:

$$\text{MassaFinal} = \frac{M_i * (100 - U_i)}{(100 - U_f)} \quad \text{Eq. (2)}$$

em que:

M_i – massa da amostra na umidade inicial;

U_i – umidade inicial;

U_f – umidade final, para a qual se pretende converter a amostra.

4.6 Análise descritiva e exploratória dos dados

Após a determinação dos atributos a serem estudados e com a finalidade de identificar e avaliar a homogeneidade e normalidade, os dados foram analisados estatisticamente por meio da estatística exploratória, calculando-se as medidas de posição: média, mediana, mínimo e máximo; as medidas de dispersão: desvio padrão, variância e coeficiente de variação (CV); e medidas de forma e distribuição: coeficientes de assimetria e curtose e normalidade.

O CV foi classificado de acordo com Pimentel-Gomes e Garcia (2002), sendo considerado baixo (homocedasticidade) quando $CV \leq 10\%$, médio quando $10\% < CV \leq 20\%$,

alto quando $20\% < CV \leq 30\%$ e muito alto (heterocedasticidade) quando $CV > 30\%$. Para avaliar a normalidade dos dados a 5% de probabilidade, foi realizado o teste de Anderson Darling e Kolmogorov-Smirnov, sendo considerados normais os dados que apresentaram normalidade em pelo menos um dos testes.

4.7 Seleção das camadas para geração das unidades de manejo

Com a finalidade de avaliar a correlação espacial entre os atributos analisados, foi utilizada a correlação cruzada entre variáveis (BONHAM; REICH; LEADER, 1995) (Equação 3), podendo-se verificar quais atributos influenciaram de forma positiva ou negativa a produtividade e se uma amostra está correlacionada espacialmente (autocorrelação espacial). Foi criada a matriz de correlação espacial, que facilitou a visualização dos resultados.

Sendo que a produtividade foi definida como atributo principal (utilizado para geração da grade de correlação), os pontos amostrais não coincidentes com os da amostragem principal foram determinados por meio da interpolação pelo inverso da distância ao quadrado, utilizando-se 8 vizinhos mais próximos de cada ponto a ser interpolado. A matriz de correlação foi gerada utilizando-se 999 iterações para avaliar cada coeficiente calculado e um nível de 95% de significância.

$$I_{YZ} = \frac{\sum_{i=1}^n \sum_{j=1}^n W_{ij} * Y_i * Z_j}{W \sqrt{m_Y^2 * m_Z^2}} \quad \text{Eq. (3)}$$

em que:

I_{YZ} – nível de associação entre a variável Y e Z, variando de -1 a 1, sendo: correlação positiva $I_{YZ} > 0$ e correlação negativa $I_{YZ} < 0$;

W_{ij} – elemento ij da matriz de associação espacial, sendo calculado por $W_{ij} = (1/(1 + D_{ij}))$ sendo D_{ij} a distância entre os pontos i e j ;

Y_i – valor da variável Y transformada no ponto i . A transformação se dá para se ter uma média zero, pela fórmula: $Y_i = (Y_i - \bar{Y})$, em que \bar{Y} é a média amostral da variável Y;

Z_j – valor da variável Z transformada no ponto j . A transformação se dá para se ter uma média zero, pela fórmula: $Z_j = (Z_j - \bar{Z})$, em que \bar{Z} é a média amostral da variável Z;

W – soma dos graus de associação espacial, obtidos por meio da Matriz W_{ij} , para $i \neq j$;

m_Y^2 – variância amostral da variável Y;

m_Z^2 – variância amostral da variável Z.

Depois de criada a matriz de correlação espacial, foram selecionados os atributos que possuem relação com a produtividade para que possam ser gerados os mapas temáticos a serem utilizados na geração de UM. O procedimento para seleção das camadas proposto por Bazzi (2011) corresponde a:

1. Eliminação das camadas com autocorrelação espacial não significativa a 95% de significância;
2. Das camadas que se apresentaram autocorrelacionadas, foram removidas as que não possuíam correlação com a produtividade;
3. Com as camadas restantes, foi realizada a ordenação decrescente, considerando o módulo do grau de correlação com a produtividade;
4. Foram eliminadas, então, as camadas redundantes (que se correlacionavam entre si) dando-se preferência para a retirada das que possuem menor correlação com a produtividade;
5. As camadas restantes foram utilizadas para geração das UM.

4.8 Análise geoestatística

Para que possa ser realizada a interpolação pelo método de krigagem, os dados foram analisados por meio da geoestatística, para identificar a estrutura da variabilidade espacial utilizando-se o estimador clássico de Matheron (Equação 4), para dados com distribuição normal, e o estimador de Cressie e Hawkins (Equação 5), para os dados que não apresentarem distribuição normal (TEIXEIRA; SCALON, 2013).

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad \text{Eq. (4)}$$

$$\hat{\gamma}(h) = \frac{1}{2} \frac{\left[N(h)^{-1} \sum_{N(h)} \sqrt{|Z(x_i + h) - Z(x_i)|} \right]^4}{0,457 + \frac{0,494}{N(h)}} \quad \text{Eq. (5)}$$

em que:

$\hat{\gamma}(h)$ – semivariância estimada;

$N(h)$ – o número de pares de valores medidos $Z(x_i)$ e $Z(x_i + h)$, separados por um vetor de distância h ;

$Z(x_i)$ e $Z(x_i + h)$ – valores da i -ésima observação da variável regionalizada Z , coletados nos pontos x_i e $x_i + h$ ($i = 1, \dots, n$), separados pelo vetor de distância h .

Para cada atributo selecionado, foram ajustados os modelos esférico, exponencial e gaussiano (CRESSIE, 1993) ao semivariograma experimental pelo método de ajuste de mínimos quadrados ordinários (CRESSIE, 1985) e a seleção do melhor modelo ajustado foi obtida por meio de estatísticas geradas pela validação cruzada (FARACO et al., 2008), utilizando o Índice de Comparação de Erros (ICE) (BAZZI et al., 2009).

Foi avaliada a dependência espacial dos dados por meio do semivariograma sendo determinado o índice de dependência espacial (CAVALCANTE et al., 2007) que foi classificado conforme Cambardella et al. (1994) (Equação 6, Tabela 1).

$$IDE = \frac{C_0}{C_0 + C_1} * 100 \quad \text{Eq. (6)}$$

em que:

IDE – índice de dependência espacial;

C0 – efeito pepita

C1 – contribuição

Tabela 1 Classificação do coeficiente de efeito pepita

Coeficiente de efeito pepita – EP	Dependência espacial
até 25%	Forte
de 25% a 75%	Moderada
acima de 75%	Fraca

Fonte: Cambardella et al. (1994)

4.9 Interpolação de dados

Foram gerados os mapas temáticos para cada atributo selecionado, interpolando-se pelos métodos o inverso da distância (ID) (Equação 7) e o inverso da distância ao quadrado (IDQ) (Equação 7) e krigagem ordinária (Equação 8), sendo que para krigagem foram utilizados os parâmetros de efeito pepita, patamar e alcance definidos na análise geoestatística.

$$Z = \frac{\sum_{i=1}^n \left(\frac{Z_i}{D_i^p} \right)}{\sum_{i=1}^n \left(\frac{1}{D_i^p} \right)} \quad \text{Eq. (7)}$$

em que:

Z – valor do atributo Z para o ponto a ser interpolado;

Z_i – valor de Z referente ao vizinho i;

D_i – distância entre o ponto a ser interpolado (Z) e o dado amostrado;

p – potência que se deseja utilizar.

$$\hat{Z}_i = \sum_{i=1}^n \lambda_i * Z_i \quad \text{Eq. (8)}$$

em que:

\hat{Z}_i – valor interpolado;

λ_i – peso atribuído aos valores amostrais;

Z_i – valor do atributo amostrado;

n – número de localidades vizinhas empregadas para a interpolação do ponto, sendo que o somatório dos pesos λ_i deve igual a um.

Para a análise geoestatística e para a plotagem dos mapas, foi utilizado o sistema computacional ArcGIS.

4.10 Definição das unidades de manejo

Com os mapas temáticos referentes aos atributos do solo selecionados, foram geradas as UM por meio do uso dos métodos de agrupamento K-Means e Fuzzy C-Means.

O algoritmo K-Means é um método de particionamento que considera $X = \{x_1, x_2, \dots, x_n\}$ um conjunto de dados de vetores no espaço vetorial R^N . O algoritmo atribui cada vetor a um único *cluster* por meio da busca do vizinho mais próximo, considerando a distância Euclidiana quadrática entre o centroide e x_n . Definida a quantidade de agrupamentos ($K = c_1, c_2, \dots, c_n$) no espaço R^N , o algoritmo particiona os clusters considerando:

1. Para cada $i \in \{1, \dots, k\}$, são adicionados os C_i para serem relacionados os pontos de X que estão mais próximos de c_i do que de c_j para todo $i \neq j$.

2. Para cada $i \in \{1, \dots, k\}$, são definidos os novos valores de c_i , considerando os

$$\text{pontos relacionados a } C_i, \text{ calculando-se } c_i = \frac{1}{|C_i|} \sum_{x_j \in C_i} x_j.$$

3. Repetem-se os passos 1 e 2 até c_i e C_i não sofrerem alterações ou pode-se configurar o número de iterações que o algoritmo deverá executar (BEZDEK, 1981).

O algoritmo Fuzzy C-Means considera um conjunto de dados $X = \{x_1, x_2, \dots, x_n\}$, em que x_k corresponde a um vetor de características $x_k = \{x_{k1}, x_{k2}, \dots, x_{kp}\} \in R^p$ para todo $k \in \{1, 2, \dots, n\}$, sendo R^p o espaço p -dimensional. Busca-se encontrar uma pseudopartição Fuzzy que corresponda a uma família de C conjuntos *Fuzzy* de X , que representa a

estrutura dos dados da melhor forma possível e é denotado por $P = \{A_1, A_2, \dots, A_C\}$, que satisfaz $\sum_{i=1}^c A_i(x_k) = 1$ e $0 < \sum_{k=1}^n A_i(x_k) < n$, em que $k \in \{1, 2, \dots, n\}$, e n representa o número de elementos de X .

O algoritmo se orienta com parâmetros referentes ao número de agrupamentos (centros) que se deseja ter C , uma medida de distância permitida entre os pontos e os centroides $m \in (1, \infty)$ e um erro utilizado como critério de parada ($\varepsilon > 0$). A pertinência inicial é atribuída aleatoriamente visando a iniciar com valores quaisquer, bem como os C centros iniciais que não devem possuir os mesmos valores iniciais devido a problemas que podem ocorrer durante a execução do algoritmo (BEZDEK, 1981).

A posição de cada centroide é calculada considerando-se a distância passada por parâmetro inicialmente. Para cada C , calculam-se $v_1^{(t)}, \dots, v_c^{(t)}$ (Equação 9) para a partição $P^{(t)}$, sendo a iteração $t = \{1, 2, \dots, n\}$. O vetor v_i corresponde ao centro do agrupamento A_i e é a média ponderada dos dados em A_i . O peso do dado x_k é a m -ésima potência do seu grau de pertinência ao conjunto Fuzzy A_i .

$$v_i = \frac{\sum_{k=1}^n [A_i(x_k)]^m x_k}{\sum_{k=1}^n [A_i(x_k)]^m} \quad \text{Eq. (9)}$$

O cálculo do grau de pertinência do elemento x_k à classe A_i (Equação 10) é realizado para cada $x_k \in X$ e para todo $i \in \{1, 2, \dots, c\}$, se $\|x_k - v_i^{(t)}\|^2 > 0$.

$$A_i^{(t+1)}(x_k) = \left[\sum_{j=1}^c \left(\frac{\|x_k - v_i^{(t)}\|^2}{\|x_k - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right]^{-1} \quad \text{Eq. (10)}$$

em que:

$\|x_k - v_i^{(t)}\|^2$ – distância entre x_k e v_i .

Como critério de parada, comparam-se $P^{(t)}$ e $P^{(t+1)}$, sendo que se $|P^{(t)} - P^{(t+1)}| \leq \varepsilon$ o algoritmo é finalizado e a classificação é realizada considerando a pertinência gerada na última iteração.

4.11 Avaliação das unidades de manejo

Na etapa de avaliação das UM, foi realizado o cálculo de eficiência relativa (ER) (Equação 11) para todos os atributos avaliados, sendo que se espera que a soma das variâncias das UM seja menor que a variância total. Para cada atributo foi realizado também o teste de comparação de médias (ANOVA) entre UM, a fim de identificar se possuem diferença média significativa. Esse teste pode ser realizado porque se assumiu que dentro de cada UM não existe dependência espacial.

$$ER = \frac{S_{AREA}^2}{S_{MZ}^2} \quad \text{Eq. (11)}$$

em que:

S_{MZ}^2 – soma da variância da produtividade de cada unidade de manejo, calculada separadamente, considerando a proporção do total da área que a unidade de manejo representa;

S_{AREA}^2 – variância da produtividade referente a toda a área.

4.12 Comparação dos mapas temáticos

As UM geradas pelos mapas interpolados pelo ID e IDQ foram comparadas com as geradas pela krigagem por meio dos índices Kappa (Equação 12) e Tau (Equação 13) (MA; REDMOND, 1995).

$$K = \frac{\left\{ n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i}) \right\}}{\left\{ n^2 - \sum_{i=1}^r (x_{i+} * x_{+i}) \right\}} \quad \text{Eq. (12)}$$

em que:

K – índice Kappa de concordância;

n – número total de observações (pontos amostrais);

r – número de classes da matriz de erro;

x_{ii} – número de combinações na diagonal;

x_{i+} – total de observações na linha i;

x_{+i} – total de observações na coluna i.

$$T = \frac{P_0 - Pr}{1 - Pr} \quad \text{Eq. (13)}$$

Os parâmetros P_0 (Equação 14) e P_r (Equação 15) podem ser explicados por:

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N} \quad \text{Eq. (14)}$$

$$P_c = \frac{\sum_{i=1}^M (n_i + n_{+i})}{N^2} \quad \text{Eq. (15)}$$

em que:

N – número total de pixels contemplados pela matriz de contingência;

n_{ij} – elementos da diagonal da matriz de contingência;

M – número de temas presentes na matriz de contingência;

P_0 – proporção de unidades que concordam plenamente;

P_c – proporção de unidades que concordam por casualidade.

Os coeficientes Kappa e Tau variam de 0 a 1. Quanto mais se aproxima do valor 1, mais a classificação se aproxima da “realidade”. Para avaliar o grau de concordância, foi utilizada a escala proposta originalmente por Landis e Koch (1977), que apresenta níveis de desempenho normalmente aceitos pela comunidade científica (Tabela 2).

Tabela 2 Classificação do grau de concordância do índice Kappa

Intervalo	Concordância
0,81 – 1,00	Muito Forte
0,61 – 0,80	Forte
0,41 – 0,60	Moderada
0,21 – 0,40	Fraca
0,00 – 0,20	Sem concordância

Fonte: Landis e Koch (1977)

5 RESULTADOS E DISCUSSÃO

5.1 Análise química do solo

A Tabela 3 apresenta as análises de estatísticas descritivas para as propriedades químicas do solo na área 1, nos anos de 2011 e 2012.

Para ambos os anos o C, a acidez, a matéria orgânica e a CTC apresentaram CV classificado como baixo (Tabela 3), indicando homogeneidade dos dados. Segundo Souza et al. (2010b), o pH do solo geralmente apresenta CV baixo, pois apresenta escala logarítmica; dessa maneira, grandes variações nas concentrações hidrogeniônicas na solução do solo resultam em pequenas variações no valor do pH. Santos et al. (2001) também encontraram dados de pH e matéria orgânica com CV baixo na profundidade de 0-20 cm do solo. Como o C é utilizado para calcular a matéria orgânica, é normal que esses dois dados sempre apresentem o mesmo comportamento.

Os atributos $H+Al^3$, Ca, Mg, Cu, Fe, Mn, soma de bases e V% apresentaram CV médio para os dois anos analisados, sendo que resultados similares foram encontrados por Bazzi (2011) também trabalhando com cultivo de soja em um latossolo localizado na região Oeste do Paraná. Os demais atributos (P, Al, K, Zn e M%) apresentaram CV muito alto, o que indica heterogeneidade nos dados analisados, também encontrada por Santos et al. (2001) para os atributos K e Zn e por Molin et al. (2007) para os atributos P e K. Segundo Cavalcante et al. (2007), o valor de CV alto para os atributos químicos do solo é provavelmente devido aos efeitos residuais de adubações anteriores.

Quanto às medidas de forma, para o ano de 2011 os atributos P, Al, $H+Al^3$, Cu, Zn, Fe e M% apresentaram dados com distribuição assimétrica positiva, ou seja, a maioria dos valores está concentrada abaixo da média. Os valores de C, pH, Ca, Mg, K, Mn, matéria orgânica, CTC, soma de bases e V% apresentaram distribuição simétrica. No ano de 2012, os dados tiveram o mesmo comportamento, com exceção do Cu que passou a apresentar distribuição assimétrica negativa, com valores concentrados acima da média.

No ano de 2011, somente o K apresentou um coeficiente de curtose classificado como platicúrtica; os atributos P, Al, Cu, Fe e M% foram classificados como leptocúrtica e os demais apresentaram distribuição classificada como mesocúrtica. Para o ano de 2012, os atributos pH, $H+Al^3$, Al, Mg, Zn, Fe e M% apresentaram-se com curtose classificada como leptocúrtica e os demais atributos evidenciaram distribuição mesocúrtica.

Não apresentaram normalidade dos dados a 5% de significância os atributos P, Cu e M% no ano de 2011. Para o ano de 2012, não foram considerados normais os atributos P, Al, Zn e M%.

A acidez ativa do solo (pH) variou de 4,60 a 5,60 no ano de 2011 e de 3,90 a 5,70 no ano de 2012. Percebe-se que houve um aumento da acidez do solo em alguns pontos no

ano de 2012, provavelmente devido ao aumento na disponibilidade de alumínio trocável que gera acidez ativa.

A soma de bases (soma de cálcio, magnésio e potássio) é considerada ideal quando a percentagem de saturação desses elementos for de 60-70, 10-20 e 2-10%, respectivamente (FURTINI NETO et al., 2001). Dessa forma, verifica-se que o solo na área em análise está em equilíbrio, pois possuía 71,7% de Ca, 20,0% de Mg e 8,3% de K no ano de 2011 e 70,0% de Ca, 22,6% de Mg e 7,4% de K em 2012.

Tabela 3 Estatística descritiva dos atributos químicos do solo da área 1 nos anos de 2011 e 2012

Química do Solo – Ano de 2011								
Atributo (unidade)	Mínimo	Média	Mediana	Máximo	DP	CV	Assimetria	Curtose
P (mg dm ⁻³) *	5,90	16,12	12,80	50,60	10,25	64 (ma)	1,98 (b)	3,91 (C)
C (g dm ⁻³)	17,92	22,00	21,82	26,10	2,03	9 (b)	-0,12 (a)	-0,32 (A)
Acidez (pH)	4,60	5,17	5,20	5,60	0,27	5 (b)	-0,35 (a)	-0,36 (A)
Al (cmolc dm ⁻³)	0,00	0,04	0,00	0,39	0,10	262 (ma)	2,67 (b)	6,34 (C)
H+Al ³ (cmolc dm ⁻³)	4,28	5,94	5,76	8,36	1,13	19 (m)	0,79 (b)	0,14 (A)
Ca (cmolc dm ⁻³)	4,52	6,40	6,30	9,37	1,06	16 (m)	0,66 (a)	0,67 (A)
Mg (cmolc dm ⁻³)	1,16	1,79	1,86	2,38	0,29	16 (m)	-0,34 (a)	-0,53 (A)
K (cmolc dm ⁻³)	0,19	0,74	0,75	1,14	0,30	40 (ma)	-0,06 (a)	-1,24 (B)
Cu (mg dm ⁻³) *	7,87	10,06	9,41	15,60	1,84	18 (m)	1,50 (b)	2,14 (C)
Zn (mg dm ⁻³)	1,72	3,93	3,48	8,32	1,34	34 (ma)	0,95 (b)	1,56 (A)
Fe (mg dm ⁻³)	19,00	27,85	27,50	50,00	5,24	18 (m)	1,85 (b)	7,05 (C)
Mn (mg dm ⁻³)	105,00	165,70	165,50	229,00	30,40	18 (m)	-0,08 (a)	-0,41 (A)
Matéria Orgânica (%)	30,89	37,94	37,62	44,99	3,49	9 (b)	-0,12 (a)	-0,32 (A)
CTC	12,81	14,87	14,88	16,70	0,90	6 (b)	-0,14 (a)	-0,09 (A)
M% *	0,00	0,55	0,00	5,85	1,47	265 (ma)	2,76 (b)	6,93 (C)
Soma de bases	6,28	8,94	8,99	12,19	1,42	15 (m)	0,14 (a)	-0,30 (A)
V%	42,9	59,96	60,68	74,01	7,78	12 (m)	-0,52 (a)	-0,11 (A)
Química do solo – Ano de 2012								
P (mg dm ⁻³) *	9,60	25,02	22,10	60,00	12,83	51 (ma)	1,19 (b)	0,73 (A)
C (g dm ⁻³)	14,03	17,96	17,92	21,82	1,74	9 (b)	0,04 (a)	-0,05 (A)
Acidez (pH)	3,90	4,96	5,00	5,70	0,36	7 (b)	-0,72 (a)	1,85 (C)
Al (cmolc dm ⁻³) *	0,00	0,13	0,00	1,12	0,24	187 (ma)	3,27 (b)	11,57 (C)
H+Al ³ (cmolc dm ⁻³)	3,97	5,98	5,76	9,70	1,14	19 (m)	1,10 (b)	2,63 (C)
Ca (cmolc dm ⁻³)	3,76	5,92	5,75	8,35	0,98	16 (m)	0,11 (a)	-0,06 (A)
Mg (cmolc dm ⁻³)	1,08	1,91	1,84	2,95	0,34	17 (m)	0,18 (a)	1,57 (C)
K (cmolc dm ⁻³)	0,25	0,63	0,64	1,12	0,21	33 (ma)	0,15 (a)	-0,68 (A)
Cu (mg dm ⁻³)	7,92	11,50	10,85	17,06	2,21	19 (m)	0,53 (a)	-0,53 (A)
Zn (mg dm ⁻³) *	1,42	3,09	2,69	8,10	1,44	46 (ma)	1,83 (b)	3,91 (C)
Fe (mg dm ⁻³)	16,00	23,90	23,0	40,00	4,62	19 (m)	1,28 (b)	2,96 (C)
Mn (mg dm ⁻³)	72,00	114,60	115,50	152,00	21,70	18 (m)	-0,15 (a)	-0,58 (A)
Matéria Orgânica (%)	24,19	30,96	30,89	37,62	2,99	9 (b)	0,04 (a)	-0,05 (A)
CTC	12,77	14,44	14,56	15,75	0,79	5 (b)	-0,37 (a)	-0,81 (A)
M% *	0,00	1,77	0,00	16,77	3,61	204 (ma)	3,51 (b)	12,80 (C)
Soma de bases	5,16	8,46	8,43	11,46	1,37	16 (m)	-0,09 (a)	0,07 (A)
V%	36,41	58,47	59,87	74,27	8,00	13 (m)	-0,71 (a)	1,36 (A)

DP – Desvio Padrão; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); * Não Normal a 5% de probabilidade

Na Tabela 4, são apresentados os níveis de interpretação dos teores dos atributos químicos do solo (muito baixo, baixo, médio, alto e muito alto) indicados por Costa e Oliveira (2001), sendo calculada em cada nível de interpretação a percentagem de cada atributo encontrada na análise química do solo para os dois anos analisados.

Os teores de P disponíveis no solo para o ano de 2011 foram 82,5% classificados como muito alto, 15% como alto e apenas 2,5% como médio, o que está em consonância com os resultados encontrados por Molin et al. (2007), ao analisar dados de um latossolo após a cultura da soja. Para o ano de 2012, todos os pontos foram classificados com níveis de P muito alto.

Para os anos de 2011 e 2012, os teores foram classificados como muito alto em mais de 92% das amostras, o que para Amado et al. (2006) é resultado do material de origem do solo, histórico de adubações, da elevada ciclagem pelas culturas de cobertura e das reduzidas perdas após a adoção do sistema de plantio direto.

Segundo Furtini Neto et al. (2001), os teores de Ca e Mg são satisfatórios em grande parte dos solos e a sua deficiência não é muito comum no solo. Os teores dos macronutrientes secundários Ca e Mg no solo foram classificados como altos em 100% dos pontos amostrados no ano de 2011. No ano de 2012, o teor de Ca apresentou menor disponibilidade no solo, sendo classificado como alto para 95% dos pontos analisados e médio para 5% dos pontos.

A matéria orgânica foi classificada em sua maioria como alta, tendo alguns valores considerados médios e apenas um caso no ano de 2012 apresentou valor classificado como baixo. Tal resultado reflete o resultado do sistema de plantio direto consolidado no talhão, que segundo Balesdent, Chenu e Balabane (2000) contribui para o aumento dos estoques de matéria orgânica presente no solo.

Os teores dos micronutrientes Cu e Mn foram classificados como altos para 100% dos pontos amostrados nos dois anos analisados.

Os valores de Zn tiveram 75% dos pontos amostrados classificados como médios para o ano de 2011. Para o ano de 2012, os níveis de Zn tiveram uma redução na sua disponibilidade, caindo para 65% dos pontos classificados como baixos.

O teor de Fe presente no solo foi em sua maioria classificado como médio para o ano de 2011, aumentando para 100% dos pontos amostrados no ano de 2012.

A CTC do solo variou de média a alta, apresentando níveis mais elevados no ano de 2012.

Segundo Furtini Neto et al. (2001), quando se faz a interpretação de resultados da análise química do solo, um dos pontos mais importantes é avaliar o teor de alumínio trocável. O teor de Al no solo encontra-se com seus níveis classificados de baixo (85%) a muito baixo (15%) no ano de 2011. Para o ano de 2012, houve um aumento em sua disponibilidade, sendo que 62,5% dos pontos foram classificados como muito baixo, 32,5% como baixo, 2,5% classificados como médio e 2,5% dos valores como alto, o que já pode ser considerado prejudicial, visto que um valor acima de $1,0 \text{ mg dm}^{-3}$ é considerado elevado e prejudicial ao crescimento das plantas.

O V% também é um importante parâmetro, pois expressa quantos por cento da CTC a pH 7,0 estão ocupados pelas bases existentes no solo. Na área em análise, o V% manteve-se de maneira geral com valores médios, tendo uma pequena melhora no ano de 2012.

Tabela 4 Níveis de interpretação dos atributos químicos do solo com a porcentagem encontrada dos pontos amostrais na área 1

Atributos	Ano	Classificação – Níveis				
		Muito baixo	Baixo	Médio	Alto	Muito alto
P (mg dm ⁻³)	2011		≤ 3,0	3,1 - 6,0	6,1 - 9,0	>9,1
	2012			2,5%	15%	82,5%
K (cmolc dm ⁻³)	2011		≤ 0,10	0,11 - 0,20	0,21 - 0,30	≥0,31
	2012			2,5%	5%	92,5%
Ca (cmolc dm ⁻³)	2011		≤ 2,0	2,0 - 4,0	≥4,0	
	2012			5%	95%	
Mg (cmolc dm ⁻³)	2011	≤0,40	0,40 - 0,60	0,61 - 0,80	≥0,80	
	2012				100%	100%
MO (g dm ⁻³)	2011	≤14,0	15,0 - 25,0	26,0 - 35,0	36,0-60,0	≥61,0
	2012		2,5%	7,5%	90%	
Cu (mg dm ⁻³)	2011		< 0,8	0,8 - 1,7	> 1,7	
	2012				100%	100%
Zn (mg dm ⁻³)	2011		< 3,0	3,0 - 7,0	>7,0	
	2012		22,5%	75%	2,5%	
Fe (mg dm ⁻³)	2011		< 15,0	15,0 - 40,0	> 40	
	2012			97,5%	2,5%	
Mn (mg dm ⁻³)	2011		< 15,0	15,0 - 30,0	>30,0	
	2012				100%	100%
CTC (cmolc dm ⁻³)	2011	≤5,0	5,0 – 8,0	8,1 - 15,0	15,1 – 20,0	≥20,0
	2012			60%	40%	
Al (mg dm ⁻³)	2011	≤0,10	0,11 - 0,50	0,51 – 1,0	1,1 – 2,0	≥2,1
	2012	85%	15%	2,5%	2,5%	
V%	2011		< 51,0	51,0 – 70,0	> 70,0	
	2012		15%	77,5%	7,5%	

Padrões de referência de Costa e Oliveira (2001)

A Tabela 5 apresenta as análises de estatísticas descritivas para as propriedades químicas do solo na área 2, no ano de 2012.

Na área 2, no ano de 2012 apenas os atributos pH e V% apresentaram CV classificado como baixo (Tabela 05), o que está em consonância com os resultados encontrados por Cavalcante et al. (2007). Os valores de pH concordam com os valores encontrados nesse trabalho para área 1 nas duas safras analisadas e com Dalchiavon et al. (2012) que também encontrou valores de pH com média muito próxima a 5,00 e CV baixo em um latossolo cultivado sob sistema de plantio direto.

Os atributos $H+Al^3$, Ca, Mn, matéria orgânica, CTC e soma de bases apresentaram CV considerado médio, concordando com Cavalcante et al. (2007), que também encontrou CV médio para o Ca, e Silva et al. (2008), que encontrou CV médio para a CTC. O K e o Cu apresentaram CV alto. Os demais atributos (P, Al, Mg, Zn, Fe e M%) tiveram CV classificado como muito alto, concordando com Dalchiavon et al. (2012), que encontrou um CV muito alto para os atributos P, Mg e M%, e Dafonte et al. (2010), para o Fe e Mg.

Quanto às medidas de forma, os atributos pH, $H+Al^3$, Ca, K, Cu, matéria orgânica, CTC, soma de bases e V% apresentaram distribuição simétrica dos dados, sendo que apenas o atributo Mn apresentou distribuição assimétrica negativa e os demais atributos (P, Al, Mg, Zn, Fe e M%) apresentaram dados com distribuição assimétrica positiva.

Quanto ao coeficiente de curtose dos dados, os atributos P, Al, Mg, Zn, Mn e M% foram classificados como de distribuição leptocúrtica e os demais apresentaram distribuição classificada como mesocúrtica.

Não apresentaram normalidade dos dados a 5% de significância os atributos Al, Cu, Zn e Mn.

Tabela 5 Estatística descritiva dos atributos químicos do solo da área 2 para o ano de 2012

Atributo (unidade)	Mínimo	Média	Mediana	Máximo	D. P.	CV	Assimetria	Curtose
P (mg dm ⁻³)	3,11	13,13	11,70	40,87	8,18	62 (ma)	1,35 (b)	2,23 (C)
Acidez (pH)	4,50	5,00	5,10	6,10	0,33	6 (b)	0,49 (a)	1,04 (A)
$H+Al^3$ (cmolc dm ⁻³)	2,95	4,26	4,28	5,35	0,52	12 (m)	-0,15 (a)	0,30 (A)
Al (cmolc dm ⁻³) *	0,00	0,03	0,00	0,21	0,06	187 (ma)	2,01 (b)	3,41 (C)
Ca (cmolc dm ⁻³)	4,23	6,28	6,16	8,69	1,06	16 (m)	0,40 (a)	-0,39 (A)
Mg (cmolc dm ⁻³)	0,33	2,35	2,23	12,12	1,69	71 (ma)	4,89 (b)	28,59 (C)
K (cmolc dm ⁻³)	0,15	0,65	0,65	1,08	0,18	28 (a)	0,14 (a)	0,68 (A)
Cu (mg dm ⁻³) *	3,49	10,28	11,05	14,35	2,67	25 (a)	-0,74 (a)	-0,34 (A)
Zn (mg dm ⁻³) *	1,31	2,91	2,64	7,93	1,13	38 (ma)	2,30 (b)	8,64 (C)
Fe (mg dm ⁻³)	21,11	53,20	48,63	122,67	22,73	42 (ma)	1,24 (b)	1,64 (A)
Mn (mg dm ⁻³) *	91,38	191,70	198,02	213,63	28,11	14 (m)	-2,89 (c)	8,06 (C)
Matéria Orgânica (%)	21,44	31,40	32,17	41,55	4,63	14 (m)	-0,09 (a)	-0,53 (A)
CTC	10,07	13,30	13,20	16,61	1,35	10 (m)	0,17 (a)	0,18 (A)
M%	0,00	0,42	0,00	3,50	0,82	197 (ma)	2,35 (b)	5,53 (C)
Soma de Bases	5,79	9,04	9,06	13,66	1,61	17 (m)	0,43 (a)	0,44 (A)
V%	57,50	67,33	67,56	82,24	5,95	8 (b)	0,12 (a)	-0,64 (A)

DP – Desvio Padrão; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); * Não Normal a 5% de probabilidade

Na Tabela 6, são apresentados os níveis de interpretação dos teores dos atributos químicos do solo (muito baixo, baixo, médio, alto e muito alto) indicados por Costa e Oliveira

(2001), sendo calculada em cada nível de interpretação a porcentagem de cada atributo encontrada na análise química do solo.

Tabela 6 Níveis de interpretação dos atributos químicos do solo com a porcentagem encontrada dos pontos amostrais, na área experimental 2

Atributos	Ano	Classificação – Níveis				
		Muito baixo	Baixo	Médio	Alto	Muito alto
P (mg dm ⁻³)	2012		≤ 3,0	3,1 - 6,0	6,1 - 9,0	>9,1
				16,7%	21,4%	61,9%
K (cmolc dm ⁻³)	2012		≤ 0,10	0,11 - 0,20	0,21 - 0,30	≥0,31
				2,4%		97,6%
Ca (cmolc dm ⁻³)	2012		≤ 2,0	2,0 - 4,0	≥4,0	
					100%	
Mg (cmolc dm ⁻³)	2012	≤0,40	0,40 - 0,60	0,61 - 0,80	≥0,80	
		2,4%			97,6%	
MO (g dm ⁻³)	2012	≤14,0	15,0 - 25,0	26,0 - 35,0	36,0-60,0	≥61,0
			16,7%	61,9%	21,4%	
Cu (mg dm ⁻³)	2012		< 0,8	0,8 - 1,7	> 1,7	
					100%	
Zn (mg dm ⁻³)	2012		< 3,0	3,0 - 7,0	>7,0	
			2,4%	38,1%	59,5%	
Fe (mg dm ⁻³)	2012		< 15,0	15,0 - 40,0	> 40	
				31%	69%	
Mn (mg dm ⁻³)	2012		< 15,0	15,0 - 30,0	>30,0	
					100%	
CTC (cmolc dm ⁻³)	2012	≤5,0	5,0 – 8,0	8,1 - 15,0	15,1 – 20,0	≥20,0
				92,9%	7,1%	
Al ³⁺ (mg dm ⁻³)	2012	≤0,10	0,11 - 0,50	0,51 – 1,0	1,1 – 2,0	≥2,1
		85,7%	14,3%			
V%	2012		< 51,0	51,0 – 70,0	> 70,0	
				57,1%	42,9%	

Padrões de referência de Costa e Oliveira (2001)

Os níveis dos macronutrientes primários P e K no solo estão classificados de médio a muito alto, com alta predominância no nível muito alto, principalmente para os valores de K.

Os teores dos macronutrientes secundários Ca e Mg no solo foram classificados como altos em 100% dos pontos amostrados para o Ca e 97,6% para o Mg, sendo que para esse último atributo houve um ponto discrepante classificado como muito baixo.

A matéria orgânica foi classificada como média em 61,9%, alta em 21,4% e baixa em 16,7%. Segundo Amado et al. (2006), os teores de matéria orgânica no solo são considerados satisfatórios, uma vez que mais de 80% dos pontos amostrais se encontram com valores que variam de médio a alto.

Os níveis dos micronutrientes de Cu e Mn foram classificados como altos para 100% dos pontos amostrados.

Os valores de Zn foram em sua maioria (59,5%) classificados como altos, com 38,1% dos pontos classificados como médios e apenas um ponto apresentou valor baixo. Os teores de Fe variam de médio (31%) a alto (69%).

A CTC do solo variou de média a alta, com a grande maioria dos pontos classificados como alta (92,9%).

O teor de Al no solo encontra-se com seus níveis classificados de baixo (14,3%) a muito baixo (85,7%). Dessa forma, o alumínio ainda não é um fator preocupante nesta área, visto que apenas acima de 1,0 mg dm⁻³ é considerado elevado e prejudicial ao crescimento das plantas.

O V% variou entre médio a alto, refletindo a positiva disponibilidade de bases presente no solo. Analisando os dados levantados, conclui-se que o solo da área experimental analisada não apresenta deficiência significativa de nenhum nutriente.

5.2 Análise das propriedades físicas do solo e topografia

A Tabela 7 apresenta a estatística descritiva dos atributos físicos do solo na área 1 para os anos de 2011 e 2012.

Tabela 7 Estatística descritiva dos atributos físicos do solo na área 1 nos anos de 2011 e 2012

Física do Solo – Ano de 2011								
Atributo (unidade)	Mínimo	Média	Mediana	Máximo	DP	CV	Assimetria	Curtose
RSP 0-0,1 (MPa)	1,01	1,58	1,52	2,79	0,43	27 (a)	1,36 (b)	1,86 (C)
RSP 0-0,2 (MPa)	1,38	1,80	1,73	2,63	0,31	17 (m)	0,94 (b)	0,53 (A)
RSP 0,1-0,2 (MPa)	1,42	2,00	1,98	2,69	0,31	15 (m)	0,38 (a)	-0,58 (A)
RSP 0,2-0,3 (MPa)	1,49	1,91	1,93	2,31	0,19	10 (b)	-0,09 (a)	2,51 (C)
Física do Solo – Ano de 2012								
Porosidade total (cm ⁻³)	0,42	0,45	0,44	0,49	0,02	4 (b)	0,32 (a)	-0,42 (A)
Macroporosidade (cm ⁻³)	0,06	0,11	0,10	0,16	0,02	21 (a)	0,49 (a)	-0,03 (A)
Microporosidade (cm ⁻³)	0,30	0,34	0,34	0,37	0,02	4 (b)	-0,28 (a)	-0,67 (A)
Densidade (g cm ⁻³)	1,24	1,35	1,34	1,47	0,06	4 (b)	0,05 (a)	-1,03 (B)
Umidade (%)	16,62	23,30	24,17	29,28	2,83	12 (m)	-0,33 (a)	-0,30 (A)
RSP 0-0,1 (MPa)	1,59	2,24	2,21	3,32	0,39	17 (m)	0,64 (a)	0,70 (A)
RSP 0-0,2 (MPa)	1,73	2,26	2,26	2,83	0,25	11 (m)	0,03 (a)	-0,22 (A)
RSP 0,1-0,2 (MPa)	1,69	2,27	2,25	2,72	0,23	9 (b)	-0,14 (a)	0,17 (A)
RSP 0,2-0,3 (MPa)	1,34	1,92	1,90	2,29	0,23	11 (m)	-0,21 (a)	-0,28 (A)
Textura do Solo -Ano de 2011								
Argila (%)	60,00	67,88	68,00	74,00	3,56	5 (b)	-0,30 (a)	-0,48 (A)
Silte (%)	14,00	20,59	20,00	26,00	2,65	12 (m)	-0,13 (a)	0,30 (A)
Areia (%)	6,00	11,53	11,00	17,00	2,88	25 (a)	0,19 (a)	-0,84 (A)
Topografia - Ano de 2012								
Altitude(m)	651,34	662,67	662,07	676,41	6,86	1 (b)	0,19 (a)	-1,02 (B)
Declividade *	0,00	2,80	1,28	21,65	4,10	147 (ma)	3,03 (b)	11,20(C)

DP – Desvio Padrão; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); * Não Normal a 5% de probabilidade

Verificou-se no ano de 2011 que na profundidade de 0,2-0,3 m, a resistência do solo a penetração apresentou CV classificado como baixo (Tabela 8), indicando homogeneidade

dos dados, uma vez que os valores variaram em menos de 10%. Nas profundidades de 0-0,2 e 0,1-0,2 m, o CV foi classificado como médio e na profundidade de 0-0,1 m, como alto.

Para o ano de 2012, a resistência do solo a penetração apresentou CV baixo apenas na profundidade de 0,1-0,2 m, sendo que nas demais profundidades (0-0,1, 0-0,2 e 0,2-0,3 m) os dados apresentaram CV considerado médio.

Embora os valores de compactação do solo tenham aumentado do ano de 2011 para o ano de 2012, segundo a classificação proposta por Canarache (1990) (Tabela 8), em média foi classificada como de baixa a média a resistência do solo a penetração, apresentando um limite de crescimento das raízes que varia entre poucas e algumas limitações.

Tabela 8 Classificação da resistência do solo a penetração

Classes	Limites (MPa)	Limites ao crescimento das raízes
Muito baixa	$\leq 1,0$	Sem limitação
Baixa	1,1 – 2,5	Pouca limitação
Média	2,6 – 5,0	Algumas limitações
Alta	5,1 – 10,0	Sérias limitações
Muito Alta	10,1 – 15,0	Raízes praticamente não crescem
Extremamente Alta	$> 15,0$	Raízes não crescem

Fonte: Canarache (1990)

O CV indicou homogeneidade ($CV < 10\%$) dos dados físicos do solo coletados no ano de 2012, com exceção da macroporosidade, que teve um $CV=21,4\%$, o que é considerado alto, em concordância com os dados obtidos por Santos, Saraiva e Molin (2012), ao trabalhar também em uma área cultivada sob sistema de plantio direto.

A porosidade total apresentou uma média de $0,45 \text{ cm}^{-3}$, sendo que $0,11 \text{ cm}^{-3}$ correspondem a macroporosidade e $0,34 \text{ cm}^{-3}$ a microporosidade.

Os valores de densidade do solo variam de $1,24$ a $1,47 \text{ g cm}^{-3}$ com média de $1,35 \text{ g cm}^{-3}$. Resultados muito próximos a estes também foram encontrados por Cavalcante et al. (2011) e Santos, Saraiva e Molin (2012).

Segundo Souza et al. (2004), a argila e a areia dos latossolos são atributos estáveis, ou seja, modificam-se pouco ao longo do tempo por ação do intemperismo. Dessa forma, a análise granulométrica do solo foi realizada apenas no ano de 2011. Segundo classificação proposta por Lemos e Santos (1984), o solo dessa área é classificado como muito argiloso, apresentando uma média de 67,9% de argila, 20,6% de silte e 11,5% de areia. A argila apresentou um CV de variação baixo (5%), enquanto que o silte apresentou CV médio (13%) e a areia um CV alto (25%).

A topografia também foi medida somente no ano de 2012, por se tratar de um atributo que praticamente não apresenta mudanças ao longo dos anos. A altitude apresentou CV baixo (1%), com média de 662,67 m e uma amplitude dos dados de 11,33 m.

A declividade apresentou um CV de variação muito alto e foi o único atributo que não apresentou normalidade dos dados a 5% de significância.

A Tabela 9 apresenta a estatística descritiva dos atributos físicos do solo na área 2 coletados em 2012.

A porosidade total do solo apresentou média de $0,25 \text{ cm}^{-3}$, sendo que a macroporosidade foi em média de $0,03 \text{ cm}^{-3}$ e a microporosidade $0,21 \text{ cm}^{-3}$. A umidade apresentou média de 29,29%. Todos esses atributos apresentaram CV baixo exceto a macroporosidade, que apresentou CV muito alto, em consonância com os resultados encontrados por Santos, Saraiva e Molin (2012).

A densidade do solo foi em média de $1,40 \text{ g dm}^{-3}$, concordando com os valores encontrados por Santos et al. (2003), com CV classificado como baixo. Ao avaliar a densidade, Faraco et al. (2008) e Siqueira, Vieira e Dechen (2009) também encontraram valores baixos para o CV.

A resistência do solo a penetração apresentou um CV médio para todas as profundidades analisadas. Segundo a classificação de Canarache (1990) (Tabela 10), em média o solo foi classificado como de muito baixa a baixa resistência a penetração, apresentando um limite de crescimento das raízes entre sem e poucas limitações.

Quanto à textura do solo, este foi classificado como muito argiloso (LEMOS; SANTOS, 1984), com em média 69,6% de argila, 26,9% de silte e 3,5% de areia. Resultados muito próximos foram encontrados também por Santos et al. (2003).

A altitude apresentou CV baixo (1,50%), com uma média de 362,83 m e amplitude dos dados de 20,99 m.

Entre os atributos físicos e topográficos analisados nessa área, apenas a macroporosidade e a resistência do solo a penetração na profundidade de 01-0,2 m e a declividade não apresentaram normalidade dos dados a 5% de significância.

Tabela 9 Estatística descritiva dos atributos físicos do solo da área 2 no ano de 2012

Física do Solo – Ano de 2012								
Atributo (unidade)	Mínimo	Média	Mediana	Máximo	DP	CV	Assimetria	Curtose
Porosidade total (cm ⁻³)	0,21	0,24	0,24	0,28	0,02	7 (b)	0,23 (a)	-0,53 (A)
Macroporosidade (cm ⁻³) *	0,02	0,03	0,03	0,09	0,01	38 (ma)	3,22 (b)	14,77 (C)
Microporosidade (cm ⁻³)	0,18	0,21	0,21	0,26	0,02	8 (b)	0,55 (a)	0,15 (A)
Densidade (g dm ⁻³)	1,24	1,40	1,39	1,49	0,06	4 (b)	-0,48 (a)	0,08 (A)
Umidade (%)	24,91	29,29	29,46	34,47	2,37	8 (b)	-0,04 (a)	-0,43 (A)
RSP 0-0,1 (MPa)	0,84	1,09	1,08	1,30	1,19	11 (m)	0,07 (a)	-0,68 (A)
RSP 0-0,2 (MPa)	0,98	1,21	1,21	1,47	1,22	10 (m)	0,21 (a)	-0,75 (A)
RSP 0,1-0,2 (MPa) *	0,94	1,19	1,13	1,54	1,74	14 (m)	0,44 (a)	-1,01 (B)
RSP 0,2-0,3 (MPa)	1,03	1,32	1,30	1,91	1,92	14 (m)	1,00 (b)	1,33 (A)
Textura do Solo – Ano de 2012								
Argila (%)	37,60	69,55	70,90	79,30	7,96	11 (m)	-1,92 (c)	5,50 (C)
Silte (%)	15,80	26,91	24,25	62,20	8,98	33 (ma)	1,71 (b)	4,80 (C)
Areia (%)	0,00	3,54	3,15	9,00	2,20	67 (ma)	0,54 (a)	-0,34 (A)
Topografia								
Altitude(m)	351,7	362,83	363,21	372,69	5,46	1 (b)	-0,21 (a)	-0,55 (A)
Declividade	0,001	0,02	0,01	0,611	0,09	382 (ma)	6,34(b)	40,74(C)

DP – Desvio Padrão; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); * Não Normal a 5% de probabilidade

5.3 Análise da produtividade

A produtividade da soja na área 1 foi avaliada em dois anos consecutivos, correspondendo aos anos agrícolas de 2011/2012 e 2012/2013.

Depois de realizada a eliminação dos dados inconsistentes, verificou-se que, no ano agrícola de 2011/2012, do total de 7883 coletados durante o processo de colheita (Figura 8a), restaram 5574 pontos (2309 pontos foram eliminados) (Figura 8b), os quais deram origem ao mapa de produtividade (Figura 8c).




Figura 8 Mapa dos pontos amostrais originais obtidos pela colhedora na área 1 safra de 2011/2012 (a), mapa de pontos amostrais restantes após a eliminação dos pontos inconsistentes (b) e mapa de produtividade da soja (c)

Para o ano agrícola de 2012/2013, do total de 24321 pontos coletados durante o processo de colheita (Figura 9a), restaram 5561 pontos (18760 pontos foram eliminados) (Figura 9b), os quais deram origem ao mapa de produtividade (Figura 9c).



Figura 9 Mapa dos pontos amostrais originais obtidos pela colhedora na área 1 safra de 2012/2013 (a), mapa de pontos amostrais restantes após a eliminação dos pontos inconsistentes (b) e mapa de produtividade da soja (c)

No ano agrícola de 2011/2012, a produtividade da soja obtida variou de $0,51 \text{ t ha}^{-1}$ a $4,41 \text{ t ha}^{-1}$ (Tabela 10), com média de $2,44 \text{ t ha}^{-1}$, ficando abaixo da média nacional, de $2,65 \text{ t ha}^{-1}$, e também um pouco abaixo da média do estado do Paraná, que foi de $2,45 \text{ t ha}^{-1}$ (CONAB, 2013a). Esses valores foram baixos devido à estiagem que atingiu a região nos meses de setembro a dezembro (Tabela 1). O CV foi classificado como muito alto (39%) e os dados não foram considerados normais a 5% de significância, apresentando distribuição simétrica dos dados e curtose classificada como mesocúrtica.

A produtividade da soja obtida no ano agrícola de 2012/2013 variou de $1,30 \text{ t ha}^{-1}$ a $8,1 \text{ t ha}^{-1}$ (Tabela 10), com média de $3,93 \text{ t ha}^{-1}$, ficando portanto acima da média nacional, de $2,93 \text{ t ha}^{-1}$, e também um pouco acima da média do estado do Paraná, de $3,34 \text{ t ha}^{-1}$ (CONAB, 2013b). A média de produtividade alta pode ser explicada pelas médias de precipitação mensal da região, que ficaram entre 150 e 330 mm para o período da safra 2012/2013 (Figura 2). O CV foi classificado como alto (20%) e os dados não foram considerados normais a 5% de significância, apresentando distribuição assimétrica positiva dos dados e curtose classificada como leptocúrtica.

Tabela 10 Estatística descritiva da produtividade da área 1 para os anos 2011/2012 e 2012/2013

Produtividade da soja – Ano agrícola 2011/2012								
Variável	Mínimo	Média	Mediana	Máximo	DP	CV	Assimetria	Curtose
Produtividade (t ha^{-1}) *	0,51	2,44	2,42	4,41	0,96	39 (ma)	-0,48 (a)	-1,03 (A)
Produtividade da soja – Ano agrícola 2012/2013								
Produtividade (t ha^{-1}) *	1,30	3,93	4,00	8,09	0,81	20 (a)	2,18 (b)	20,14(C)

DP – Desvio Padrão; * Não Normal a 5% de probabilidade; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); ** Segundo classificação proposta por Jones (1969) a 5% de significância

Na área 2, além da soja, foi avaliada a produtividade do milho no ano agrícola de 2012/13. A produtividade do milho variou de $2,53$ a $4,85 \text{ t ha}^{-1}$ (Tabela 11) (Figura 10), com média de 4 t ha^{-1} , ficando abaixo da média nacional, de $5,11 \text{ t ha}^{-1}$, e também da média estadual, de $5,79 \text{ t ha}^{-1}$. Esses valores são bastante reduzidos devido à ocorrência de fortes chuvas em excesso, com média de 330 mm de precipitação mensal nessa região ainda no

estágio de maturidade do milho, prejudicando a colheita (Figura 2). O CV foi classificado como médio (17,52%) e os dados foram considerados normais a 5% de significância.

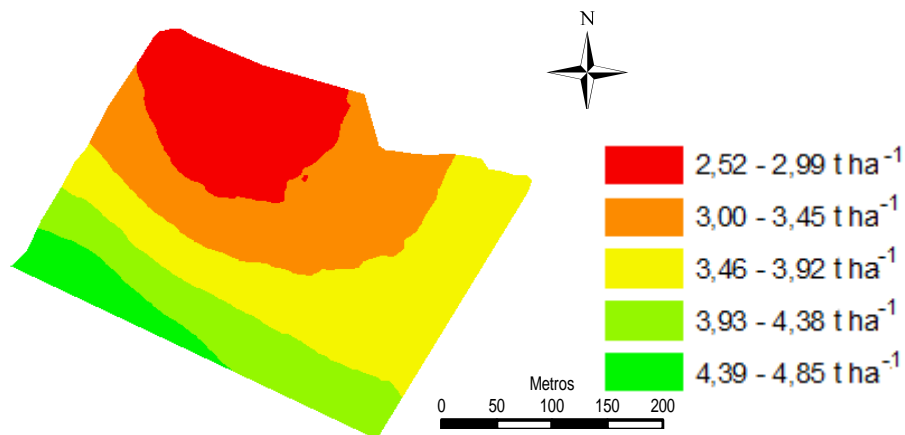


Figura 10 Mapa de produtividade da do milho na área 2 safra 2013

A produtividade da soja variou de 2,42 t ha⁻¹ a 6,61 t ha⁻¹ (Figura 11), com média de 5,07 t ha⁻¹, ficando acima da média de produtividade obtida no estado para essa mesma safra e também da média nacional, devido às adequadas médias de precipitação na região durante o período da safra, que podem ser verificadas na Figura 2. O CV foi classificado como médio (14%) e os dados foram considerados normais a 5% de probabilidade, apresentando distribuição assimétrica negativa dos dados e curtose classificada como leptocúrtica.

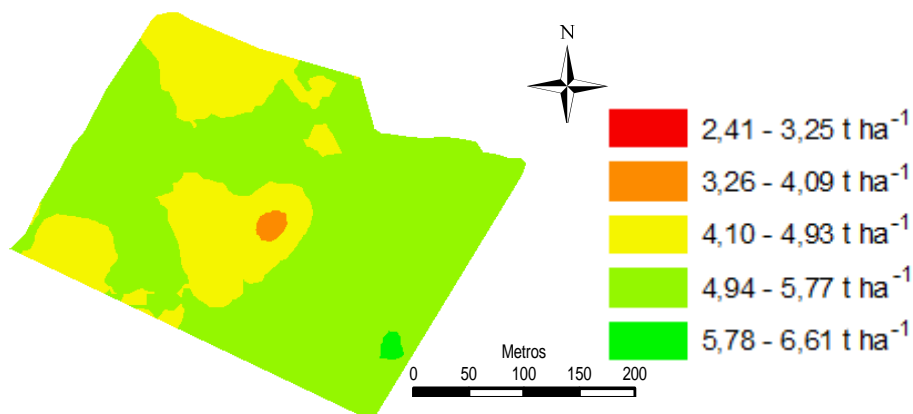


Figura 11 Mapa de produtividade da soja na área 2 safra da soja 2012/2013

Tabela 11 Estatística descritiva da produtividade da área 2 para o ano agrícola 2012/2013

Variável	Mínimo	Média	Mediana	Máximo	D. P.	CV	Assimetria	Curtose
Produtividade milho (t ha ⁻¹)	2,53	3,45	3,44	4,85	0,60	18 (m)	-1,15 (c)	3,89(C)
Produtividade soja (t ha ⁻¹)	2,42	5,07	5,06	6,61	0,69	14 (m)	-1,01 (c)	4,28(C)

DP – Desvio Padrão; * Não Normal a 5% de probabilidade; CV – Coeficiente de Variação: baixo (b); médio (m), alto (a), muito alto (ma); Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); ** Segundo classificação proposta por Jones (1969) a 5% de significância

5.4 Análise de correlação espacial

Na Figura 12, é apresentada a matriz de correlação cruzada entre todas as variáveis analisadas na área 1 para safra da soja 2011/2012.

Com vistas à seleção dos atributos do solo para geração das UM, inicialmente foram eliminados os atributos que não apresentaram autocorrelação espacial: Ca, C, CTC, Fe, P, Mg, MO, K, RSP 0-0,1 m, RSP 0-0,2 m e silte.

Quanto aos demais atributos, foram eliminados os atributos declividade, Mn e Zn, que não apresentaram correlação significativa com a produtividade

Após a aplicação desse procedimento de seleção das variáveis, restaram os atributos altitude, Al, areia, argila, Cu, $H+Al^3$, pH, RSP 0,1-0,2 e RSP 0,2-0,3 m. Realizou-se, então, a ordenação decrescente desses atributos de acordo com o nível de correlação de cada um deles com a produtividade (Tabela 12). Como houve correlações negativas (areia e Cu), foram utilizados os valores absolutos referentes aos níveis de correlação.

Com os atributos restantes, foram analisados os que possuem correlação significativa entre si, eliminando-se sempre os que possuem menor correlação com a produtividade. Como todos os atributos apresentaram correlação espacial com a altitude, e esse atributo possui um grau de correlação maior com a produtividade da soja, ele foi utilizado para geração das UM.

Tabela 12 Ordem de classificação de atributos candidatos à geração de UM

Atributo	altitude	RSP 0,2-0,3	areia	Cu	argila	$H+Al^3$	pH	RSP 0,1-0,2	Al
Correlação	0,153	0,141	-0,116	-0,081	0,067	0,060	-0,039	0,036	0,034
Ordem	1	2	3	4	5	6	7	8	9

Na Figura 13, é apresentada a matriz de correlação cruzada entre todas as variáveis analisadas na área 1 para safra de 2012/2013.

A produtividade correlacionou com a resistência do solo a penetração em todas as profundidades, em consonância com os resultados encontrados para essa mesma área na safra da soja 2011/2012 e também com os resultados encontrados por Santos et al. (2005). Entre os demais atributos físicos analisados, a produtividade correlacionou de forma negativa com a umidade, porém esse atributo não apresentou autocorrelação espacial.

Apresentaram correlação significativa positiva com a produtividade o silte e a altitude. Portanto, a altitude correlacionou com a produtividade da soja nas duas safras analisadas, em consonância com os resultados encontrados por Souza et al. (2010a) e Montezano, Corazza e Muraoka (2008), que também encontraram correlação positiva da produtividade com a altitude, indicando que, nas áreas menos elevadas do talhão, a produtividade foi menor.

A altitude correlacionou também com pH, Al, Ca, Cu, Mg, Mn, $H+Al^3$, K, M%, V%, declividade, densidade, macroporosidade, microporosidade, porosidade total, areia e argila.

Com vistas à seleção dos atributos do solo para geração das UM, inicialmente foram eliminados os atributos que não apresentaram autocorrelação espacial, isto é, pH, Ca, C, CTC, declividade, densidade, Fe, P, $H+Al^3$, macroporosidade, Mg, matéria orgânica, microporosidade, K, silte, umidade, V%, Zn, RSP 0,2-0,3, RSP 0-0,2 e RSP 0,1-0,2 m.

Quanto aos demais atributos, foram eliminados os que não possuem correlação significativa com a produtividade (Al, areia, argila, Cu, Mn, M% e porosidade total).

Após a aplicação desse procedimento de seleção de variáveis, restaram apenas os atributos altitude e RSP 0-0,1 m para geração das UM (Tabela 13).

Tabela 13 Ordem de classificação dos atributos candidatos à geração de UM

<i>Atributo</i>	altitude	RSP 0-0,1
Correlação	0,114	0,125
Ordem	1	2

Na Figura 14, é apresentada a matriz de correlação cruzada entre todas as variáveis analisadas na área 2 no ano agrícola de 2012/2013.

Com relação aos atributos químicos, a produtividade da soja correlacionou somente com o atributo químico P e de forma positiva. Dos atributos físicos do solo, os que apresentaram correlação com a produtividade da soja foram a densidade do solo microporosidade e a resistência do solo a penetração nas profundidades de 0-0,1 e 0-0,2 m, todos com correlação positiva.

Apresentaram correlação significativa com a produtividade do milho os atributos químicos pH (correlação positiva), Cu, Fe, H+Al³, K e Zn (correlação negativa). Os atributos físicos areia, umidade e porosidade total correlacionaram de forma positiva, enquanto que declividade, silte, densidade, microporosidade e resistência mecânica do solo a penetração em todas as profundidades analisadas correlacionaram negativamente. A altitude e declividade correlacionaram positiva e negativamente, respectivamente.

Para realizar a seleção dos atributos do solo para geração das UM, primeiro foram eliminados os atributos que não apresentaram autocorrelação espacial: declividade, pH, areia, Ca, Cu, CTC, Fe, H+Al³, Mn, M.O, K, soma de bases, V%, microporosidade, porosidade total, RSP 0-0,1, RSP 0-0,2 e RSP 0,1-0,2 m.

Com vistas à geração das UM para cultura da soja, foram eliminados os atributos areia, Mg, silte, V%, Zn, macroporosidade e RSP 0,2-0,3 m, por não possuírem correlação com a produtividade dessa cultura. Restaram apenas os atributos P e densidade, que se correlacionam entre si. Dessa forma, como o P apresentou um índice de correlação com a produtividade maior do que a densidade, esse atributo foi utilizado para geração das UM para a soja.

Para seleção das variáveis utilizadas na geração das UM da produtividade do milho, foram eliminados atributos do solo Al, argila, P, Mg e macroporosidade, por não apresentarem correlação com a produtividade, restando então os atributos altitude, RSP 0,2-0,3 m, densidade, umidade, zinco e silte.

Esses atributos foram, então, ordenados conforme o grau de correlação em módulo com a produtividade. Como a densidade e a RSP 0,2-0,3 m correlacionaram com a altitude, esses dois atributos foram então eliminados. Restaram os atributos altitude, umidade, Zn e silte para geração da UM.

Tabela 14 Ordem de classificação dos atributos candidatos à geração de UM para cultura do milho

<i>Atributo</i>	altitude	RSP 0,2-0,3	densidade	umidade	Zn	silte
Correlação	0,114	0,125	-0,097	0,05	0,042	0,031
Ordem	1	2	3	4	5	6

5.5 Análise geoestatística

Na área 1, foi realizada a análise geoestatística dos atributos altitude e RSP 0,10 m, que foram selecionados para geração das UM. Como esses dois atributos apresentaram normalidade dos dados, foram calculadas as semivariâncias por meio do método de Matheron, sendo ajustados os modelos esférico, exponencial e gaussiano ao semivariograma.

Para cada modelo, foram obtidos os parâmetros de efeito pepita, patamar e alcance, e a seleção do melhor modelo foi realizada utilizando-se o índice de comparação de erros (ICE). O modelo exponencial foi selecionado como melhor para ambos os atributos (Tabela 15).

Considerando o modelo selecionado, o índice de dependência espacial (Tabela 16) foi considerado forte para a altitude e moderado para a RSP 0-0,1 m.

Tabela 15 Parâmetros do semivariograma para escolha do melhor modelo dos atributos selecionados para geração das UM na área 1

Atributo	Modelo	C ₀	C ₁	Patamar	Alcance	IDE%	ER	SER	ICE
Altitude	Esférico	0	60,048	60,048	0,003	0,00	0,004	0,625	1,68
	<u>Exponencial</u>	<u>0</u>	<u>69,495</u>	<u>69,495</u>	<u>0,005</u>	<u>0,00</u>	<u>0,003</u>	<u>0,554</u>	<u>1,60</u>
	Gaussiano	6,85	55,485	62,337	0,003	10,99	-0,005	0,63	1,71
RSP 0-0,1	Esférico	9873	9577	1945	0,005	50,76	-0,036	1,062	1,81
	<u>Exponencial</u>	<u>8538</u>	<u>1018</u>	<u>1872</u>	<u>0,005</u>	<u>45,61</u>	<u>-0,028</u>	<u>1,058</u>	<u>1,57</u>
	Gaussiano	1142	9497	2092	0,005	54,60	-0,044	1,059	1,95

C₀ – Efeito Pepita; C₁ – Contribuição; IDE% – Índice de Dependência Espacial: fraca (f), moderada (m) e forte (fo); ER – erro médio reduzido; SER – desvio padrão do erro médio reduzido; ICE – índice de Comparação de Erros; sublinhado indica o melhor modelo

Na área 2, foi realizada a análise geoestatística dos atributos Fósforo e Densidade, selecionados para geração das UM para a cultura da soja, e dos atributos Altitude, Umidade e Zinco, selecionados para geração das UM para cultura do milho. Como todos esses atributos apresentaram normalidade dos dados, também foram calculadas as semivariâncias por meio do método de Matheron, sendo ajustados os modelos esférico, exponencial e gaussiano ao semivariograma.

O modelo esférico foi selecionado como melhor modelo para o Fósforo, altitude, Umidade e Zinco, mas o modelo exponencial foi o que se ajustou melhor ao atributo Densidade.

Considerando o modelo selecionado, o índice de dependência espacial (Tabela 16) foi considerado forte apenas para a Densidade. O Fósforo e a altitude apresentaram dependência espacial moderada e a Umidade e o Zinco, fraca.

Tabela 16 Parâmetros do semivariograma para escolha do melhor modelo dos atributos selecionados para geração das UM na área 2

Atributo	Modelo	C ₀	C ₁	Patamar	Alcance	IDE%	ER	SER	ICE
Fósforo	<u>Esférico</u>	<u>37,13</u>	<u>50,45</u>	<u>87,57</u>	<u>0,004</u>	<u>42,39</u>	<u>0,0004</u>	<u>1,074</u>	<u>1,11</u>
	Exponencial	30,26	53,49	83,75	0,004	36,13	0,000	1,077	1,15
	Gaussiano	45,04	50,62	95,66	0,004	47,08	0,003	1,067	1,87
Densidade	<u>Esférico</u>	<u>0,002</u>	<u>0,003</u>	<u>0,005</u>	<u>0,004</u>	<u>33,20</u>	<u>0,003</u>	<u>1,093</u>	<u>1,98</u>
	<u>Exponencial</u>	<u>0,001</u>	<u>0,004</u>	<u>0,005</u>	<u>0,004</u>	<u>24,55</u>	<u>0,000</u>	<u>1,086</u>	<u>0,93</u>
	Gaussiano	0,002	0,003	0,005	0,004	40,03	0,0024	1,095	1,76
Altitude	<u>Esférico</u>	<u>15,87</u>	<u>23,42</u>	<u>39,29</u>	<u>0,004</u>	<u>40,39</u>	<u>0,000</u>	<u>1,007</u>	<u>0,60</u>
	Exponencial	12,68	24,81	37,49	0,004	33,82	-0,003	1,014	1,82
	Gaussiano	19,62	23,33	42,96	0,004	45,68	0,0039	0,9918	1,59
Umidade	<u>Esférico</u>	<u>5,10</u>	<u>0,63</u>	<u>5,73</u>	<u>0,002</u>	<u>88,99</u>	<u>0,0102</u>	<u>1,035</u>	<u>0,87</u>
	Exponencial	2,11	3,58	5,69	0,001	37,08	0,00361	1,058	1,97
	Gaussiano	3,72	1,97	5,68	0,001	65,38	0,00353	1,06	1,98
Zinco	<u>Esférico</u>	<u>1,24</u>	<u>0,05</u>	<u>1,29</u>	<u>0,003</u>	<u>95,93</u>	<u>0,03</u>	<u>1,031</u>	<u>1,81</u>
	<u>Exponencial</u>	<u>1,28</u>	<u>0</u>	<u>1,28</u>	<u>0,003</u>	<u>100</u>	<u>0,03</u>	<u>1,021</u>	<u>1,60</u>
	Gaussiano	1,24	0,08	1,32	0,003	94,12	0,02	1,035	1,92

C₀ – Efeito Pepita; C₁ – Contribuição; IDE% – Índice de Dependência Espacial: fraca (f), moderada (m) e forte (fo); ER – erro médio reduzido; SER – desvio padrão do erro médio reduzido; ICE – índice de comparação de erros; sublinhado indica o melhor modelo

5.6 Interpolação de dados


Com o intuito de avaliar a influência dos interpoladores na geração das UM, primeiro foram gerados os mapas temáticos para cada atributo selecionado da matriz de correlação espacial, interpolando-se os dados por ID, IDQ e krigagem. Dessa forma, na área 1 foram gerados os mapas temáticos dos atributos altitude (Figura 15) e RSP 0-0,1 m (Figura 16), utilizando os três interpoladores.

Devido ao fato de a interpolação pelo método IDQ gerar menores valores de mínimo e maiores valores de máximo entre os valores obtidos por todos os interpoladores, os mapas para cada atributo foram classificados em 5 classes de mesma amplitude, utilizando-se como base os valores de máximo e mínimo obtidos pelo IDQ.


Verifica-se visualmente que os mapas gerados por krigagem apresentaram contornos entre classes mais suaves, como consequência da suavização ocorrida no processo de interpolação por meio desse método.

Quanto ao mapa temático da altitude do terreno (Figura 15), é possível perceber que os maiores valores estão localizados na região nordeste e que há um decréscimo no sentido sudeste do mapa.

A RSP 0-0,1 m (Figura 16) teve seus menores valores localizados no norte do mapa, aumentando no sentido sudeste do mapa.




a) ID b) IDQ c) KRI
 Figura 15 Mapas temáticos do atributo altitude, interpolados por ID (a), IDQ (b) e krigagem (c)




a) ID b) IDQ c) KRI
 Figura 16 Mapas temáticos do atributo RSP 0-0,1 m, interpolados por ID (a), IDQ (b) e krigagem (c)

Na área 2, considerando-se a produtividade da soja foram gerados os mapas temáticos dos atributos Fósforo (Figura 17) e Densidade (Figura 18).




a) ID b) IDQ c) KRI
 Figura 17 Mapas temáticos do atributo Fósforo, interpolados por ID (a), IDQ (b) e krigagem (c)




a) ID b) IDQ c) KRI
 Figura 18 Mapas temáticos do atributo Densidade, interpolados por ID (a), IDQ (b) e krigagem (c)


Também na área 2, mas considerando a produtividade do milho, foram gerados os mapas temáticos dos atributos Altitude (Figura 19), Umidade (Figura 20) e Zinco (Figura 21).



a) ID b) IDQ c) KRI
 Figura 19 Mapas temáticos do atributo Altitude, interpolados por ID (a), IDQ (b) e KRI (c)



a) ID b) IDQ c) KRI
 Figura 20 Mapas temáticos do atributo Umidade, interpolados por ID (a), IDQ (b) e krigagem (c)



a) ID b) IDQ c) KRI
 Figura 21 Mapas temáticos do atributo Zinco, interpolados por ID (a), IDQ (b) e krigagem (c)

5.7 Definição das UM

Com os dados interpolados pelos três algoritmos de interpolação (ID, IDQ e krigagem), foram geradas as UM por meio da utilização dos métodos de agrupamento K-Means e Fuzzy C-Means. Tais UM foram divididas em duas, três e quatro classes de manejo.

Para área 1, safra da soja 2011/2012, foram geradas as UM com o atributo altitude (Figuras 22, 23 e 24).

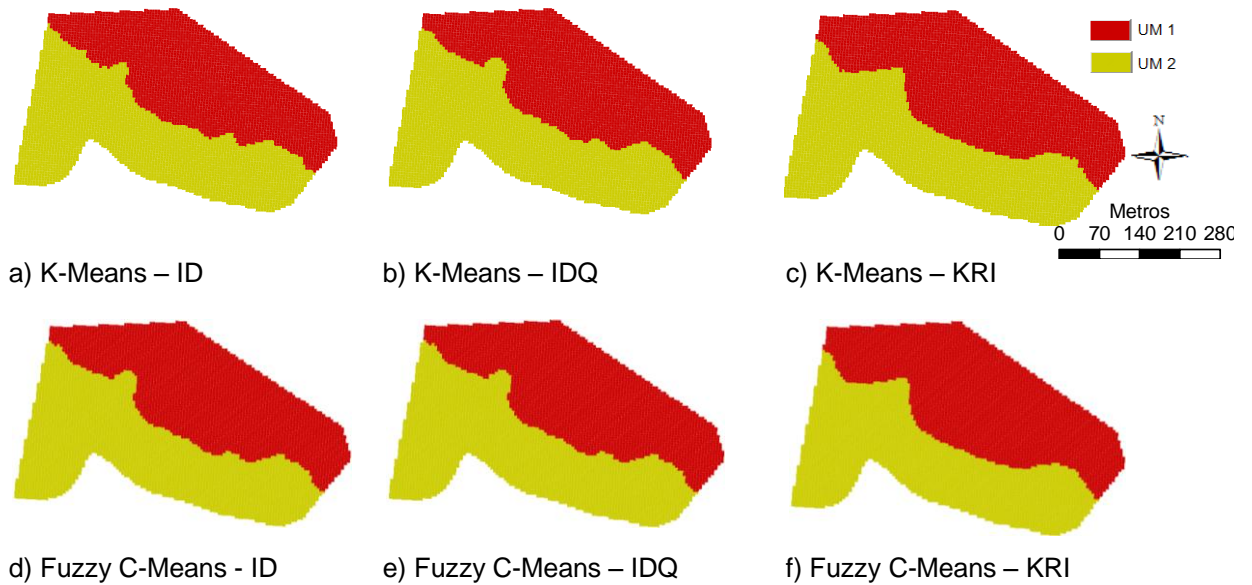


Figura 22 Unidades de Manejo geradas para área 1 safra 2011/2012 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

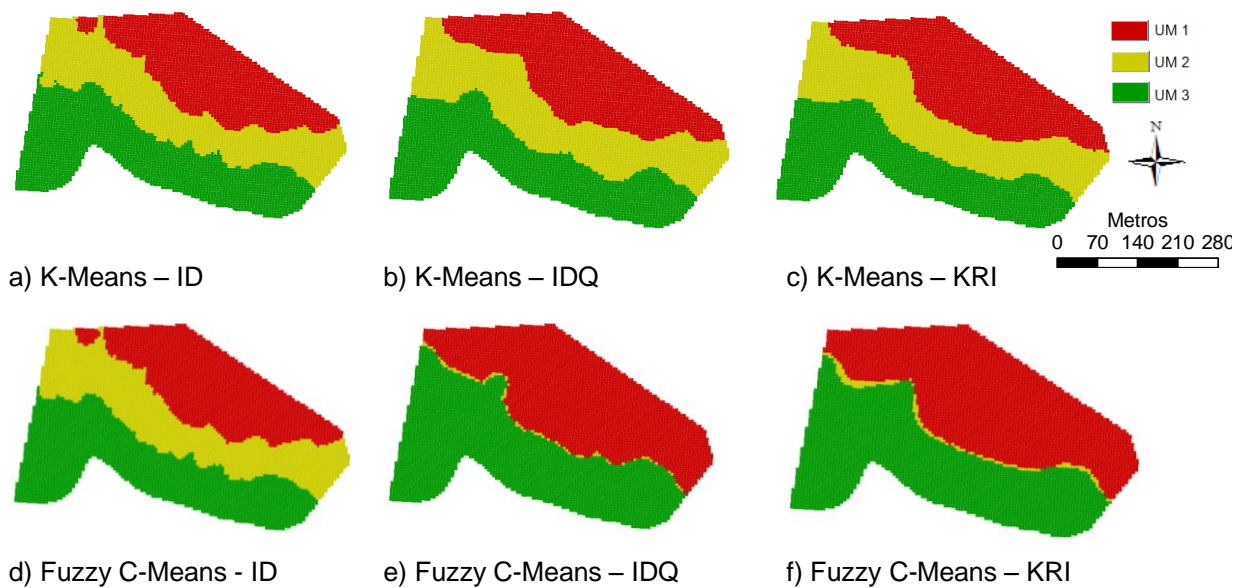


Figura 23 Unidades de Manejo geradas para área 1 safra 2011/2012 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

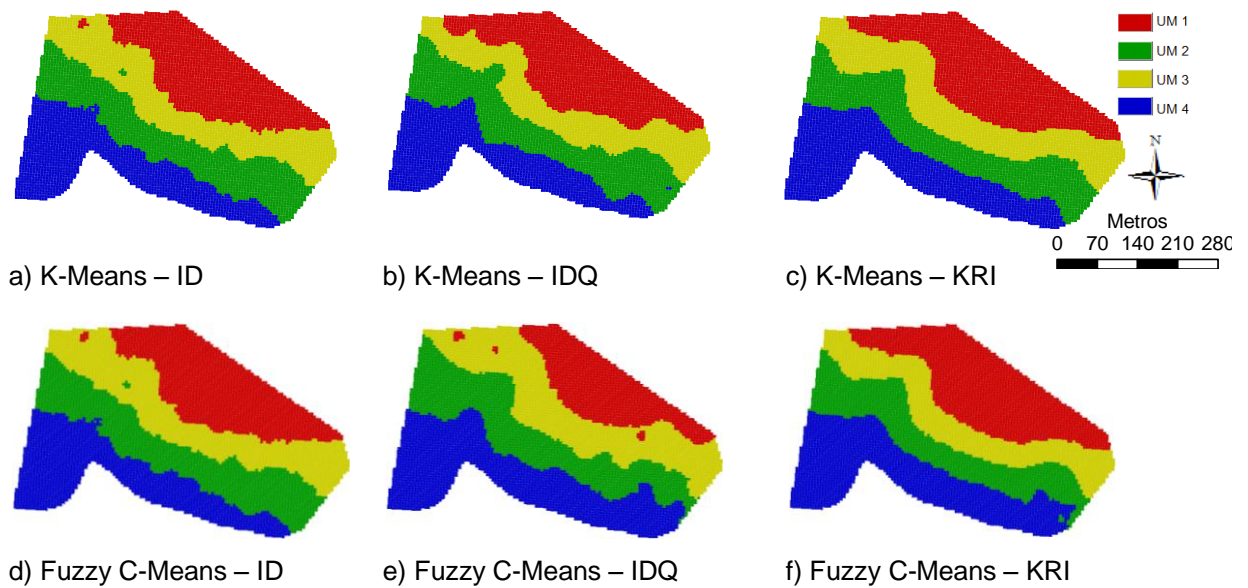


Figura 24 Unidades de Manejo geradas para área 1 safra 2011/2012 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

Para área 01, safra da soja 2012/2013, foram geradas as UM com os atributos altitude e RSP 0,10 cm (Figuras 25, 26 e 27).

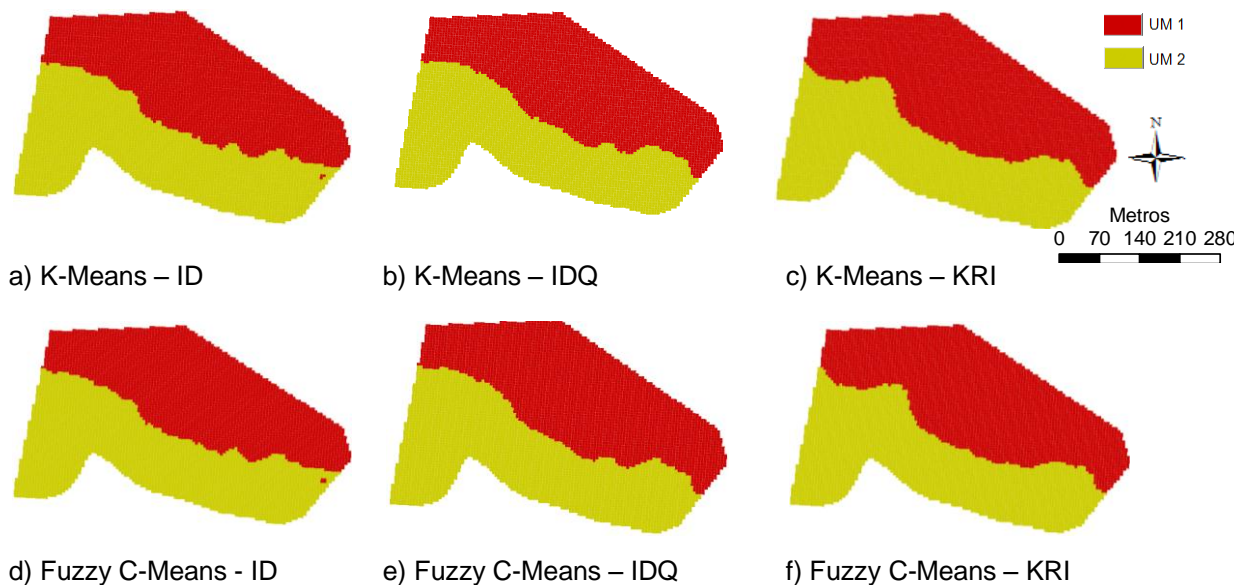


Figura 25 Unidades de Manejo geradas para área 1 safra 2012/2013 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

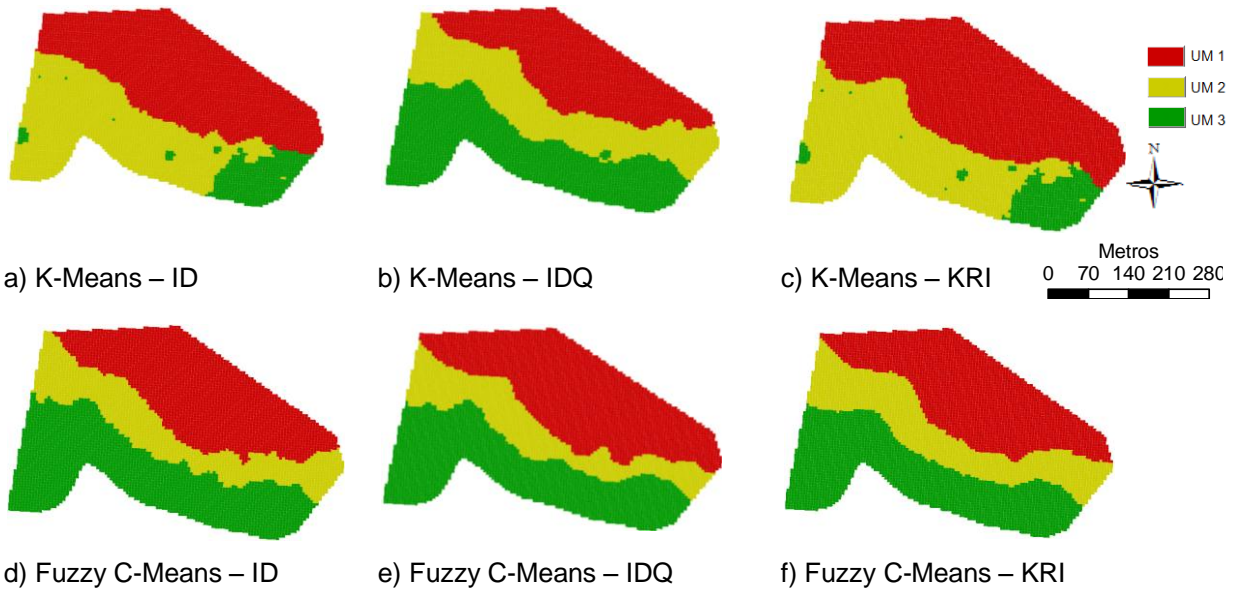


Figura 26 Unidades de Manejo geradas para área 1 safra 2012/2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

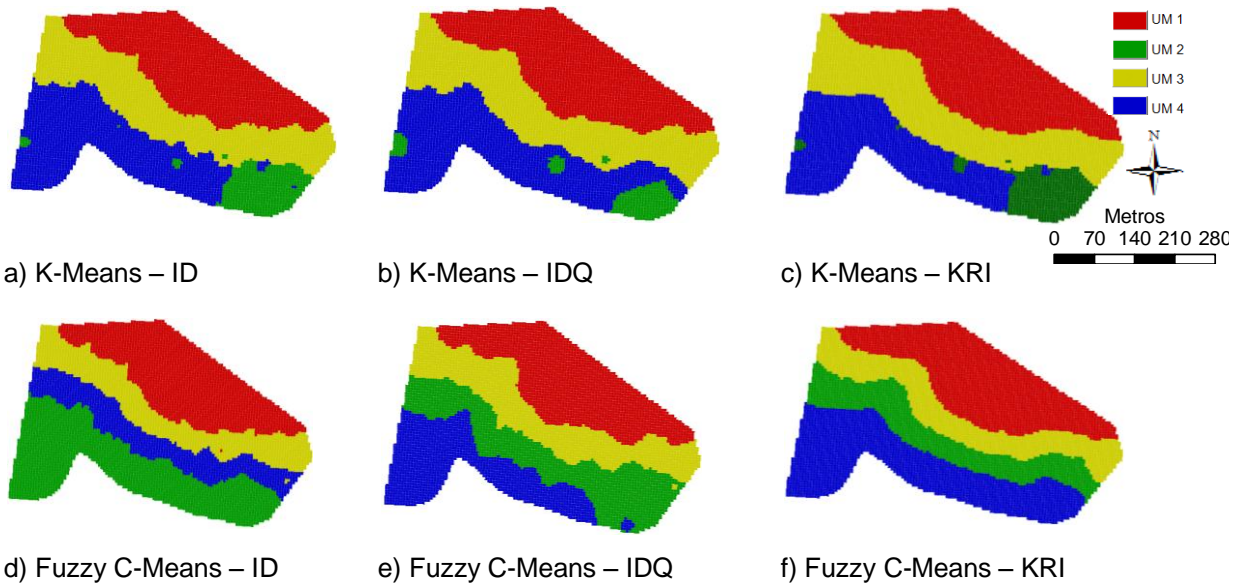


Figura 27 Unidades de Manejo geradas para área 1 safra 2012/2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

Para área 2, safra da soja 2012/2013, foram geradas as UM com os atributos Fósforo e Densidade (Figuras 28, 29 e 30).





Figura 28 Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)


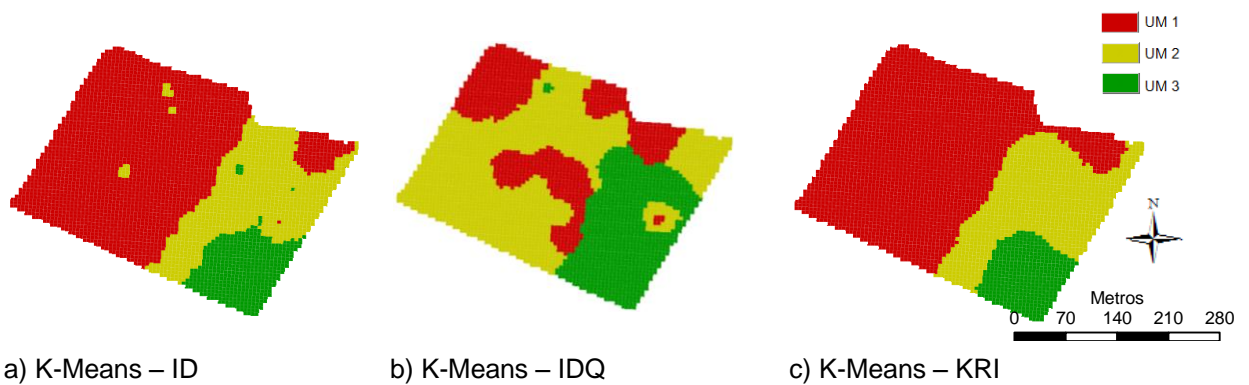


Figura 29 Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)


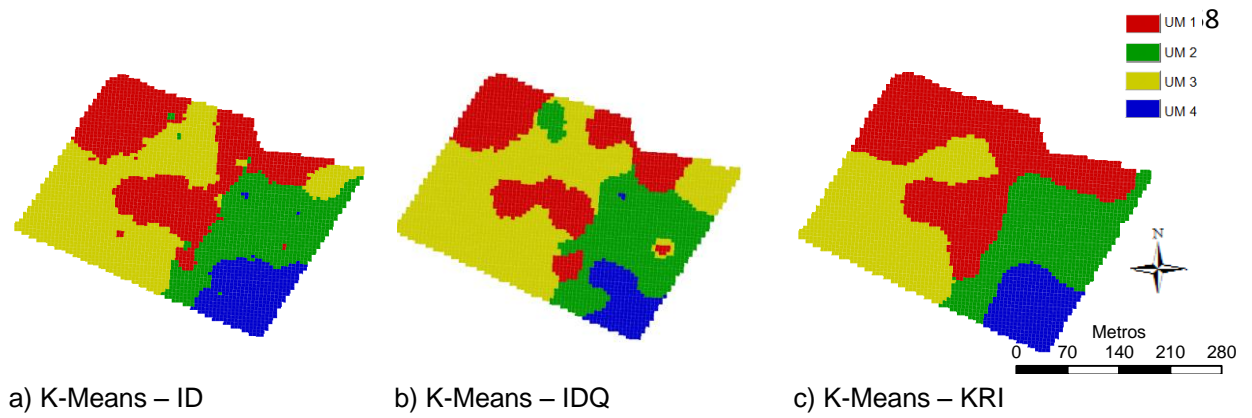


Figura 30 Unidades de Manejo geradas para área 2 safra da soja 2012/2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

Para área 2, safra do milho 2013, foram geradas as UM com os atributos altitude, umidade e zinco (Figuras 31, 32 e 33).

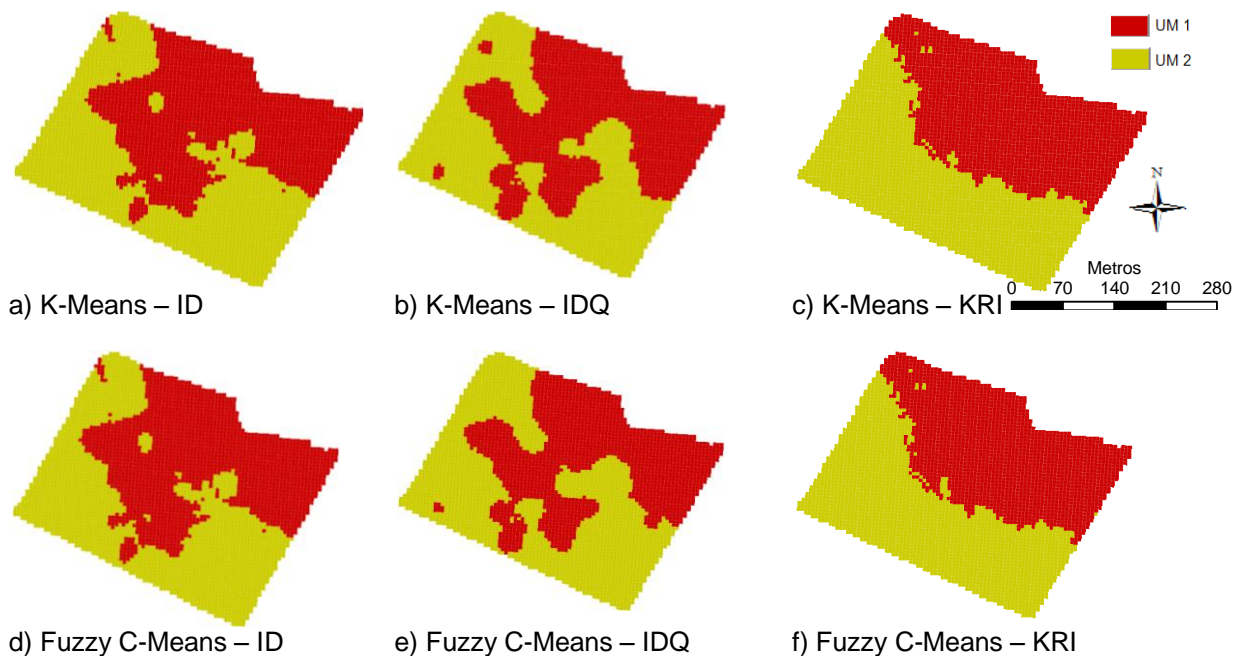


Figura 31 Unidades de Manejo geradas para área 2 safra do milho 2013 com duas classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

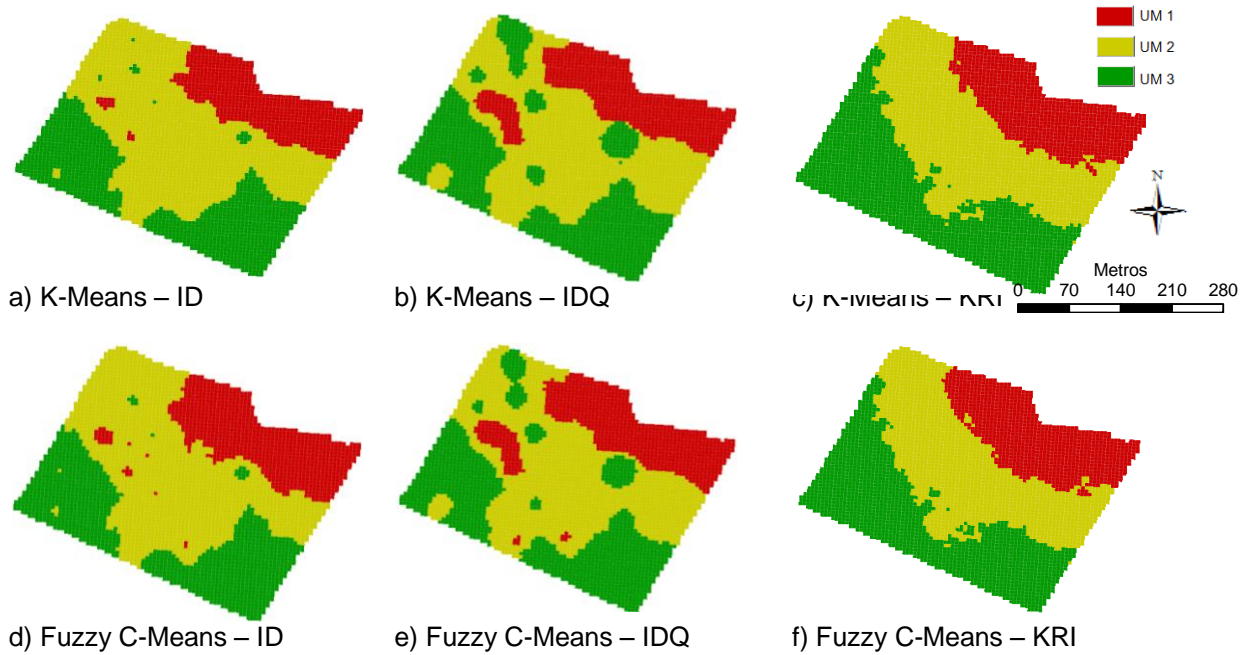


Figura 32 Unidades de Manejo geradas para área 2 safra do milho 2013 com três classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

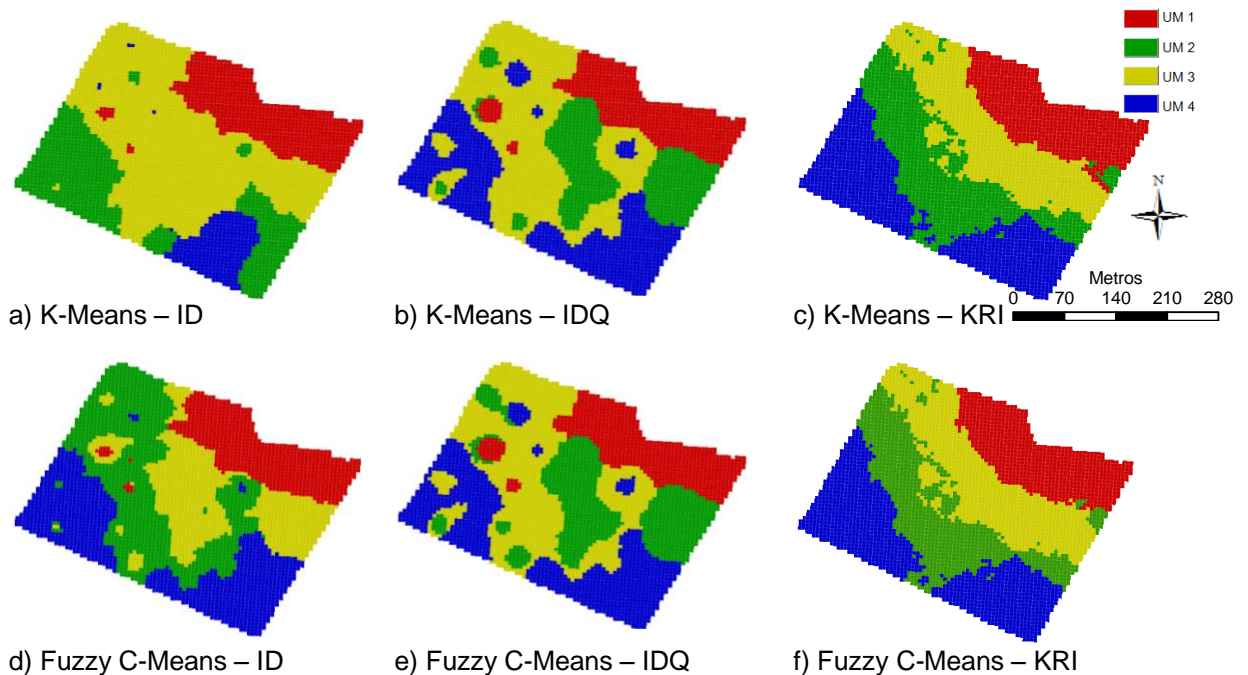


Figura 33 Unidades de Manejo geradas para área 2 safra do milho 2013 com quatro classes utilizando dois algoritmos de agrupamento (K-Means e Fuzzy C-Means) e três interpoladores (ID – Inverso da distância; IDQ – Inverso da distância ao Quadrado; KRI – krigagem ordinária)

5.8 Avaliação das UM

Na área 1, safra da soja 2011/2012, para as UM geradas com duas, três e quatro classes pelo algoritmo K-Means, independentemente do método de interpolação utilizado, a análise de variância (ANOVA) mostrou que a produtividade média da soja das UM (Tabela 17) é estatisticamente diferente a 95% de significância.

O coeficiente de eficiência relativa demonstrou que a divisão entre as UM foi válida para todos os casos analisados, pois $ER \geq 1,00$, sendo que em todos os casos houve redução da variância total de no mínimo 56%.

Tabela 17 Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 1 safra 2011/2012, separados por UM e gerada pelo algoritmo K-Means

N classes	Interpolador	U. M.	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	48	2732	0,64	3,25a	4,4	0,50	0,15	0,28	2,27
		2	52	2842	0,51	1,66b	4,1	0,55	0,33		
	IDQ	1	49	2750	0,64	3,24a	4,4	0,51	0,16	0,29	3,20
		2	51	2824	0,51	1,65b	4,1	0,56	0,34		
	KRI	1	51	2991	0,64	3,18a	4,4	0,56	0,18	0,26	3,49
		2	49	2583	0,51	1,57b	4,1	0,44	0,29		
3	ID	1	31	1662	2,16	3,33a	4,4	0,40	0,12	0,33	2,75
		2	32	1853	0,54	2,65b	4,3	0,86	0,33		
		3	37	2059	0,51	1,51c	2,6	0,35	0,23		
	IDQ	1	33	1772	2,14	3,34a	4,4	0,40	0,12	0,35	2,63
		2	32	1841	0,53	2,55b	4,3	0,88	0,35		
		3	35	1961	0,51	1,51c	2,6	0,36	0,24		
	KRI	1	34	1810	2,16	3,33a	4,4	0,40	0,12	0,36	2,59
		2	32	1841	0,53	2,51b	4,3	0,90	0,36		
		3	35	1923	0,51	1,52c	2,6	0,36	0,24		
4	ID	1	26	1377	2,17	3,35a	4,3	0,38	0,11	0,23	3,90
		2	25	1522	0,64	3,09b	4,4	0,62	0,20		
		3	24	1358	0,53	1,63c	3,9	0,54	0,33		
		4	25	1317	0,51	1,54d	2,6	0,35	0,23		
	IDQ	1	28	1508	2,16	3,36a	4,4	0,39	0,12	0,25	3,60
		2	22	1358	0,64	3,06b	4,3	0,62	0,20		
		3	26	1423	0,53	1,67c	4,1	0,61	0,36		
		4	24	1285	0,51	1,55d	2,6	0,36	0,23		
	KRI	1	27	1498	2,16	3,36a	4,4	0,39	0,11	0,25	3,77
		2	24	1494	0,64	3,01b	4,3	0,66	0,22		
		3	24	1179	0,53	1,59c	4,1	0,54	0,34		
		4	25	1403	0,51	1,55d	2,6	0,35	0,23		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na avaliação das UM referentes à área 1 para cultura da soja (safra 2011/2012), utilizando o algoritmo Fuzzy C-Means (Tabela 18), a ANOVA mostrou diferença significativa na produtividade da soja para todas as divisões (2, 3 e 4), independentemente do método de interpolação utilizado, como já havia sido verificado com K-Means.

Verificou-se, por meio do coeficiente de eficiência relativa, que a divisão entre as UM foi válida para todos os casos analisados, reduzindo-se a variância em pelo menos 63%.

Tabela 18 Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 1 safra 2011/2012, separados por UM e gerada pelo algoritmo Fuzzy C-Means

N ^o	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER	
2	ID	1	49	2783	0,64	3,23a	4,4	0,51	0,16	0,28	3,27	
		2	51	2791	0,51	1,64b	4,1	0,54	0,33			
	IDQ	1	49	2783	0,64	3,23a	4,4	0,51	0,16	0,28	3,27	
		2	51	2791	0,51	1,64b	4,1	0,54	0,33			
	KRI	1	52	3009	0,64	3,18a	4,4	0,57	0,18	0,26	3,47	
		2	48	2565	0,51	1,56b	4,1	0,44	0,28			
3	ID	1	31	1676	2,16	3,33a	4,4	0,40	0,12	0,33	2,73	
		2	32	1842	0,54	2,65b	4,3	0,87	0,33			
		3	37	2056	0,51	1,51c	2,6	0,35	0,23			
	IDQ	1	48	2744	0,64	3,24a	4,4	0,51	0,16	0,27	3,40	
		2	2	82	1,21	2,76b	4,1	0,71	0,26			
		3	50	2748	0,51	1,62c	4,1	0,52	0,32			
	KRI	1	50	2878	0,64	3,22a	4,4	0,52	0,27	0,24	3,78	
		2	2	151	0,88	2,25b	3,9	0,86	0,38			
		3	48	2545	0,51	1,56c	4,1	0,43	0,28			
	4	ID	1	26	1361	2,17	3,35a	4,3	0,38	0,11	0,23	3,90
			2	25	1544	0,64	3,09b	4,4	0,62	0,20		
			3	25	1386	0,53	1,63c	3,9	0,53	0,33		
4			24	1283	0,51	1,54d	2,6	0,35	0,23			
IDQ		1	18	964	2,16	3,34a	4,3	0,40	0,12	0,29	3,17	
		2	27	1583	0,64	3,24b	4,4	0,48	0,15			
		3	25	1376	0,53	1,97c	4,2	0,80	0,40			
		4	30	1651	0,51	1,52d	2,6	0,36	0,24			
KRI		1	28	1555	2,16	3,36a	4,4	0,39	0,12	0,25	3,71	
		2	21	1269	0,64	3,08b	4,3	0,58	0,19			
		3	22	1170	0,53	1,74c	4,1	0,66	0,38			
		4	29	1580	0,51	1,53d	2,6	0,35	0,23			

* ANOVA com 95% de significância; N^o – número de classes; N – número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 1, safra da soja 2012/2013, para as UM geradas com duas, três e quatro classes pelo algoritmo K-Means, a ANOVA mostrou que a produtividade média da soja das UM é estatisticamente diferente a 95% de significância, independentemente do método de interpolação utilizado (Tabela 19).

Apesar de as divisões apresentarem resultados satisfatórios quanto à produtividade média distinta entre UM, o coeficiente de eficiência relativa demonstrou que em vários casos não houve redução da variância ou mesmo esta foi pequena.

Tabela 19 Estatística descritiva e eficiência relativa dos dados de produtividade da área 1 safra da soja 2012/2013, separados por UM e gerada pelo algoritmo K-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	51	2632	1,30	4,05a	11,7	0,91	0,23	0,65	1,00
		2	49	2929	1,34	3,82b	11,6	0,67	0,18		
	IDQ	1	52	2721	1,30	4,05a	11,7	0,90	0,22	0,65	1,00
		2	48	2840	1,34	3,82b	11,6	0,68	0,18		
	KRI	1	54	2783	1,30	4,05a	11,7	0,89	0,22	0,65	1,00
		2	46	2778	1,34	3,81b	11,6	0,69	0,18		
3	ID	1	51	2614	1,30	4,05a	11,7	0,92	0,23	0,65	1,00
		2	39	2318	1,34	3,83b	11,6	0,69	0,18		
		3	10	629	1,48	3,78c	5,2	0,59	0,16		
	IDQ	1	33	1793	1,30	3,94a	11,7	0,85	0,22	0,64	1,01
		2	30	1515	1,36	4,14b	11,6	0,88	0,21		
		3	37	2253	1,34	3,79c	11,6	0,68	0,18		
	KRI	1	53	2733	1,30	4,04a	11,7	0,90	0,22	0,65	1,00
		2	38	2239	1,34	3,83b	11,6	0,71	0,18		
		3	9	589	1,48	3,77c	5,2	0,60	0,16		
4	ID	1	32	1761	1,30	3,95a	11,3	0,82	0,21	0,64	1,01
		2	30	1521	1,36	4,12b	11,7	0,91	0,22		
		3	8	590	1,48	3,75c	5,2	0,60	0,16		
		4	30	1689	1,34	3,81d	11,6	0,70	0,18		
	IDQ	1	33	1810	1,30	3,94a	11,7	0,85	0,22	0,64	1,02
		2	31	1534	1,36	4,13b	11,6	0,88	0,21		
		3	5	270	1,48	3,61c	4,7	0,65	0,18		
		4	31	1947	1,34	3,81d	11,7	0,67	0,18		
	KRI	1	34	1878	1,30	3,95a	11,7	0,84	0,21	0,64	1,01
		2	30	1594	1,34	4,08b	11,6	0,90	0,22		
		3	10	584	1,48	3,73c	5,2	0,61	0,16		
		4	26	1505	1,37	3,82d	11,6	0,67	0,18		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 1, safra da soja 2012/2013, para as UM geradas com duas, três e quatro classes pelo algoritmo Fuzzy C-Means, a ANOVA mostrou diferença significativa a 95% de significância entre as médias de produtividade da soja das UM (Tabela 20), independentemente do método de interpolação utilizado.

O coeficiente de eficiência relativa demonstrou que a redução da variância foi pequena para todos os casos, pois ER foi próximo a 1, indicando que os resultados das divisões não foram adequados.

Tabela 20 Estatística descritiva dos dados de produtividade da área 1 safra da soja 2012/2013, separados por UM, distância e gerada pelo algoritmo Fuzzy C-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	51	2606	1,30	4,05a	11,7	0,92	0,23	0,65	1,00
		2	49	2955	1,34	3,82b	11,6	0,67	0,18		
	IDQ	1	51	2633	1,30	4,05a	11,7	0,91	0,22	0,65	1,00
		2	49	2928	1,34	3,82b	11,6	0,68	0,18		
	KRI	1	53	2719	1,30	4,04a	11,7	0,90	0,22	0,65	1,00
		2	47	2842	1,34	3,82b	11,6	0,69	0,18		
3	ID	1	43	2255	1,30	3,99a	11,7	0,81	0,20	0,64	1,01
		2	21	1115	1,36	4,09b	11,6	0,98	0,24		
		3	36	2191	1,34	3,79c	11,6	0,67	0,17		
	IDQ	1	42	2212	1,30	3,98a	11,7	0,82	0,20	0,64	1,01
		2	22	1135	1,36	4,11b	11,6	0,96	0,23		
		3	36	2214	1,34	3,78c	11,6	0,68	0,18		
	KRI	1	38	2008	1,30	3,96a	11,7	0,82	0,21	0,65	1,00
		2	26	1401	1,34	4,08b	11,6	0,95	0,23		
		3	36	2152	1,37	3,80c	11,6	0,65	0,17		
4	ID	1	36	1920	1,30	3,96a	11,7	0,83	0,21	0,64	1,02
		2	21	1066	1,42	4,23b	11,6	0,93	0,22		
		3	10	592	1,36	3,92c	9,5	0,74	0,19		
		4	33	1983	1,34	3,77d	11,7	0,67	0,18		
	IDQ	1	29	1672	1,30	3,97a	11,3	0,81	0,20	0,65	1,00
		2	24	1112	1,43	4,17b	11,7	1,00	0,24		
		3	25	1564	1,34	3,78c	11,6	0,74	0,20		
		4	22	1213	1,37	3,86d	7,5	0,60	0,15		
	KRI	1	31	1724	1,30	3,94a	11,7	0,86	0,22	0,64	1,01
		2	20	875	1,43	4,25b	11,6	0,97	0,23		
		3	19	1267	1,34	3,90c	11,6	0,75	0,19		
		4	30	1695	1,37	3,78d	7,5	0,63	0,22		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 2, safra da soja 2012/2013, para as UM geradas com duas classes pelo algoritmo K-Means, a ANOVA mostrou diferença significativa a 95% de significância entre as médias de produtividade da soja das UM (Tabela 21) independentemente do método de interpolação utilizado.

Verificou-se que, conforme o coeficiente de eficiência relativa, todas as divisões foram válidas por reduzir pelo menos 5% da variância total quando realizaram-se as divisões da área em UM.

Tabela 21 Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 2, separados por UM e gerada pelo algoritmo K-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	72	33	2,42	4,90a	6,1	0,64	0,13	0,38	1,29
		2	28	9	4,96	5,69b	6,6	0,54	0,09		
	IDQ	1	74	30	2,42	4,91a	6,1	0,67	0,14	0,44	1,12
		2	26	12	4,49	5,46b	6,6	0,63	0,12		
	KRI	1	71	32	2,42	4,91a	6,1	0,65	0,13	0,40	1,20
		2	29	10	4,68	5,59b	6,6	0,60	0,11		
3	ID	1	62	26	2,42	4,93a	6,1	0,71	0,14	0,44	1,11
		2	26	9	4,49	5,02a	6,6	0,64	0,13		
		3	12	7	5,05	5,67b	6,2	0,39	0,07		
	IDQ	1	25	11	2,42	4,70a	5,6	0,87	0,18	0,41	1,19
		2	50	21	3,96	5,02a	6,1	0,49	0,10		
		3	25	10	4,49	5,57b	6,6	0,63	0,11		
	KRI	1	62	28	2,42	4,89a	6,1	0,69	0,14	0,43	1,14
		2	27	9	4,68	5,29ab	6,6	0,63	0,12		
		3	11	5	5,05	5,66b	6,2	0,45	0,08		
4	ID	1	31	14	2,42	4,77a	5,6	0,81	0,17	0,46	1,05
		2	36	16	3,96	5,03ab	6,1	0,51	0,10		
		3	22	5	4,49	5,19bc	6,6	0,82	0,16		
		4	11	7	5,04	5,67bc	6,2	0,39	0,07		
	IDQ	1	24	11	2,42	4,70a	5,6	0,87	0,18	0,44	1,11
		2	45	19	3,96	5,03b	6,1	0,51	0,10		
		3	24	8	4,49	5,40ab	6,6	0,73	0,13		
		4	7	4	5,05	5,61b	5,9	0,39	0,07		
	KRI	1	38	16	2,42	4,76a	5,6	0,75	0,16	0,45	1,09
		2	28	16	3,96	5,06a	6,1	0,52	0,10		
		3	23	5	4,68	5,52a	6,6	0,77	0,14		
		4	11	5	5,05	5,66ab	6,2	0,45	0,08		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 2, safra da soja 2012/2013, para as UM geradas com duas classes pelo algoritmo Fuzzy C-Means, a ANOVA não apresentou diferença significativa a 95% de significância entre as médias de produtividade da soja das UM (Tabela 22) para os métodos ID e IDQ apesar de que por meio do coeficiente de eficiência relativa foi possível identificar até 6% de redução da variância dos dados gerais. Quando utilizado o interpolador KRI, a redução da variância foi de 15% e a divisão apresentou-se satisfatória, com produtividade média distinta entre UM.

Para divisão em três e quatro classes, verificou-se por meio do coeficiente de eficiência relativa que houve redução de pelo menos 8% da variância com dados interpolados pela krigagem (divisão de quatro classes).

Tabela 22 Estatística descritiva e eficiência relativa dos dados de produtividade da soja na área 2, separados por UM e gerada pelo algoritmo Fuzzy C-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	66	28	2,42	4,93a	6,1	0,69	0,14	0,46	1,07
		2	34	14	4,49	5,35a	6,6	0,65	0,12		
	IDQ	1	64	26	2,42	4,92a	6,1	0,71	0,14	0,46	1,06
		2	36	16	4,49	5,32a	6,6	0,61	0,12		
	KRI	1	65	29	2,42	4,90a	6,1	0,68	13,4	0,42	1,15
		2	35	13	4,68	5,46b	6,6	0,60	0,11		
3	ID	1	31	13	2,42	4,75a	5,5	0,78	0,16	0,39	1,27
		2	40	20	3,96	5,00a	6,1	0,53	0,11		
		3	29	9	4,96	5,69b	6,6	0,54	0,09		
	IDQ	1	20	9	4,58	5,00a	5,5	0,31	0,06	0,45	1,09
		2	51	20	2,42	4,86ab	6,1	0,79	0,16		
		3	29	13	4,49	5,45ac	6,6	0,61	0,11		
	KRI	1	32	13	2,42	4,71a	5,4	0,78	0,16	0,41	1,20
		2	39	19	3,96	5,04a	6,1	0,53	0,11		
		3	29	10	4,68	5,59b	6,6	0,60	0,11		
4	ID	1	27	10	2,42	4,76a	5,6	0,96	0,20	0,42	1,17
		2	33	16	3,96	5,03a	6,1	0,51	0,10		
		3	16	7	4,49	4,81a	5,2	0,27	0,06		
		4	24	9	4,96	5,69b	6,6	0,54	0,09		
	IDQ	1	10	3	4,48	4,72a	4,9	0,26	0,05	0,44	1,10
		2	47	19	2,42	4,88ab	6,1	0,81	0,17		
		3	16	8	4,58	5,08a	5,5	0,31	0,06		
		4	27	12	4,49	5,46ac	6,6	0,63	0,12		
	KRI	1	26	8	2,42	4,60a	5,4	0,97	0,21	0,45	1,08
		2	33	18	3,96	5,05a	6,1	0,54	0,11		
		3	14	6	4,49	4,89a	5,2	0,27	0,06		
		4	27	10	4,68	5,59b	6,6	0,60	0,11		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 2, safra do milho 2013, para as UM geradas com duas classes pelo algoritmo K-Means, a ANOVA apresentou diferença significativa a 95% de significância entre as médias de produtividade do milho das UM (Tabela 23) apenas para ID e KRI. Apesar de as proporções de áreas serem as mesmas para IQD, tanto ANOVA como ER apresentaram resultados insatisfatórios.

Apesar de a divisão em quatro UM geradas com o interpolador IDQ não permitir a redução da variância dos dados de produtividade, pois ER = 1, verificou-se que para os demais casos houve redução da variância de até 63% nos mapas gerados pela KRI na divisão em quatro classes.

Tabela 23 Estatística descritiva e eficiência relativa dos dados de produtividade do milho na área 2, separados por UM e gerada pelo algoritmo K-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	49	18	2,68	3,25a	4,1	0,40	0,12	0,36	1,01
		2	51	25	2,53	3,75b	4,8	0,80	0,20		
	IDQ	1	49	21	2,77	3,40a	4,1	0,40	0,12	0,38	0,96
		2	51	21	2,53	3,57a	4,8	0,77	0,22		
	KRI	1	49	15	2,53	3,13a	3,8	0,38	0,12	0,27	1,35
		2	51	27	3,03	3,80b	4,8	0,62	0,16		
3	ID	1	19	7	2,77	3,10a	3,5	0,33	0,11	0,30	1,22
		2	50	16	2,53	3,34a	4,3	0,51	0,15		
		3	31	19	3,36	3,98b	4,8	0,69	0,17		
	IDQ	1	21	9	2,78	3,15a	3,5	0,28	0,09	0,36	1,02
		2	44	13	2,68	3,59a	4,8	0,67	0,19		
		3	35	20	2,53	3,43a	4,8	0,64	0,19		
	KRI	1	22	7	2,77	3,08a	3,5	0,30	0,10	0,23	1,56
		2	40	19	2,53	3,23a	3,8	0,41	0,13		
		3	38	16	3,33	4,02b	4,8	0,63	0,16		
4	ID	1	23	11	3,35	3,99a	4,8	0,76	0,19	0,32	1,02
		2	50	16	2,53	3,35b	4,3	0,51	0,15		
		3	18	14	2,76	3,10a	3,5	0,33	0,10		
		4	9	1	3,95	3,95a	3,9	-	-		
	IDQ	1	17	7	3,09	3,31a	3,5	0,22	0,07	0,37	1,00
		2	36	10	2,53	3,29a	4,8	0,79	0,24		
		3	20	11	2,77	3,46a	4,1	0,43	0,12		
		4	27	14	3,36	3,81a	4,8	0,60	0,12		
	KRI	1	19	4	2,77	3,08a	3,5	0,30	0,10	0,22	1,63
		2	26	12	2,68	3,33a	3,8	0,42	0,13		
		3	27	12	2,53	3,30a	4,1	0,46	0,14		
		4	28	14	3,39	4,27b	4,8	0,61	0,14		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

Na área 2, safra do milho 2013, para as UM geradas com duas classes pelo algoritmo Fuzzy C-Means, a ANOVA apresentou diferença significativa a 95% de significância entre as médias de produtividade do milho das UM (Tabela 24) apenas para os métodos ID e KRI, assim como ocorreu para o algoritmo K-Means, apresentando também aumento da variância geral, pois ER = 0,95.

O coeficiente de eficiência relativa demonstrou que a divisão entre as UM foi válida para todos os casos nas divisões em três e quatro classes, exceto para as UM geradas com três classes com dados interpolados pelo método IDQ, pois apresentaram ER=1,00, indicando que não houve redução da variância.

Tabela 24 Estatística descritiva e eficiência relativa dos dados de produtividade do milho na área 2, separados por UM e gerada pelo algoritmo Fuzzy C-Means

N classes	Interpolador	UM	%área	N	Mín	Média	Máx	DP	CV	Var. Total	ER
2	ID	1	49	19	2,70	3,25a	4,1	0,39	0,12	0,36	1,01
		2	51	23	2,53	3,75b	4,8	0,75	0,20		
	IDQ	1	46	20	2,77	3,37a	4,1	0,41	0,10	0,38	0,95
		2	54	22	2,53	3,52a	5,8	0,75	0,21		
	KRI	1	49	14	2,53	3,13a	3,8	0,38	0,12	1,88	1,35
		2	51	28	3,03	3,80b	4,8	0,62	0,16		
3	ID	1	22	7	2,77	3,22a	3,8	0,42	0,13	0,30	1,22
		2	48	20	2,53	3,31a	4,3	0,50	0,15		
		3	30	15	3,39	4,11b	4,8	0,69	0,17		
	IDQ	1	22	11	2,78	3,15a	3,5	0,28	0,09	0,37	1,00
		2	45	11	2,68	3,51a	4,8	0,64	0,18		
		3	33	20	2,53	3,54a	4,8	0,70	0,20		
	KRI	1	23	8	2,77	3,19a	3,8	0,40	0,12	0,24	1,54
		2	40	17	2,53	3,17a	3,7	0,38	0,12		
		3	37	17	3,33	4,02b	4,8	0,63	0,16		
4	ID	1	18	7	2,78	3,18a	3,5	0,32	0,10	0,30	1,22
		2	24	13	2,77	3,41a	4,1	0,43	0,13		
		3	31	8	2,53	3,18a	4,3	0,59	0,19		
		4	27	14	3,39	4,11b	4,8	0,69	0,17		
	IDQ	1	18	7	3,09	3,31a	3,5	0,22	0,07	0,35	1,04
		2	33	9	2,53	3,29a	4,8	0,79	0,24		
		3	23	12	2,77	3,46a	4,1	0,43	0,07		
		4	26	14	3,36	3,81a	4,8	0,60	0,16		
	KRI	1	19	4	2,77	3,08a	3,5	0,30	0,10	0,23	1,62
		2	27	11	2,68	3,33a	3,8	0,42	0,13		
		3	26	13	2,53	3,30a	4,1	0,46	0,14		
		4	28	14	3,39	4,27b	4,8	0,61	0,14		

* ANOVA com 95% de significância; N – Número de amostras de produtividade; Mín – Mínimo; Max – Máximo; DP – Desvio Padrão; CV – Coeficiente de Variação; ER – Eficiência Relativa; Var. Total – Soma das variâncias das UM, considerando o percentual de área

A influência do tipo de interpolador na maior porcentagem de diferença de área entre as classes de manejo (Tabela 25) variou entre 0 e 37%. Já as maiores médias de diferença foram de 9,2% e 9,1%, ocorridas entre os métodos IDQ e KRI e ID e IDQ gerados pelo método de agrupamento K-Means, e as menores diferenças foram de 5 e 5,7% entre os interpoladores ID e KRI gerados pelos métodos de agrupamento K-Means e Fuzzy C-Means. Portanto, as maiores diferenças foram observadas ao se utilizar o método IDQ.

Tabela 25 Maior porcentagem de diferença de área entre os métodos de interpolação ID, IDQ e KRI nas áreas 1 e 2 considerando os métodos de agrupamento K-Means e Fuzzy C-Means

área	safra	N ^o	Método de agrupamento					
			K-Means			Fuzzy C-Means		
			#ID-IDQ	#ID-KRI	#IDQ-KRI	#ID-IDQ	#ID-KRI	#IDQ-KRI
1	Soja 2011 /	2	1%	3%	2%	0%	0%	3%
		3	2%	3%	0%	30%	30%	2%
		4	3%	1%	2%	8%	4%	10%
	Soja 2012 /	2	1%	3%	2%	0%	2%	2%
		3	27%	2%	28%	1%	5%	4%
		4	3%	4%	5%	15%	9%	8%
2	Soja 2012 /	2	2%	1%	3%	2%	1%	1%
		3	37%	1%	37%	11%	1%	12%
		4	9%	8%	17%	17%	3%	16%
Milho 2013	2	0%	0%	0%	3%	0%	3%	
	3	6%	10%	4%	3%	8%	5%	
	4	18%	24%	10%	9%	5%	6%	
Média			9,1%	5,0%	9,2%	8,3%	5,7%	6,0%

N^o – número de classes; # – diferença de área entre os métodos de interpolação

A ANOVA mostrou que a krigagem foi o método que obteve mais diferenças significativas entre as classes nas UM geradas (Tabela 26), sendo que o ID apresentou menos diferenças significativas entre as divisões. Já a média da eficiência relativa das UM geradas com dados interpolados por krigagem foi de 1,78, sendo que este pode então ser considerado o melhor método de interpolação utilizado para geração das UM. O ID apresentou média de E.R 1,60 e o IDQ 1,58, sendo que este último pode ser considerado o método menos indicado. Tem-se, portanto, que o melhor método de interpolação foi a krigagem seguida do ID, justificando-se a escolha do interpolador mais robusto (krigagem) na geração de UM.

Tabela 26 Análise de variância e eficiência relativa considerando o método de interpolação (ID, IDQ e KRI)

Área	Safr	Método	Nº	Método de Interpolação					
				ID		IDQ		KRI	
				ANOVA*	ER	ANOVA*	ER	ANOVA*	ER
1	Soja 2011 / 2012	K- Means	2	Sim	2,27	Sim	3,20	Sim	3,49
			3	Sim	2,75	Sim	2,63	Sim	2,59
			4	Sim	3,90	Sim	3,60	Sim	3,77
		Fuzzy C- Means	2	Sim	3,27	Sim	3,27	Sim	3,47
			3	Sim	2,73	Sim	3,40	Sim	3,78
			4	Sim	3,90	Sim	3,17	Sim	3,71
	Soja 2012 / 2013	K- Means	2	Sim	1,00	Sim	1,00	Sim	1,00
			3	Sim	1,00	Sim	1,01	Sim	1,00
			4	Sim	1,01	Sim	1,02	Sim	1,01
		Fuzzy C- Means	2	Sim	1,00	Sim	1,00	Sim	1,00
			3	Sim	1,01	Sim	1,01	Sim	1,00
			4	Sim	1,01	Sim	1,00	Sim	1,01
2	Soja 2012 / 2013	K- Means	2	Sim	1,29	Sim	1,12	Sim	1,20
			3	Não	1,11	Não	1,19	Não	1,14
			4	Não	1,05	Não	1,11	Não	1,09
		Fuzzy C- Means	2	Não	1,07	Não	1,06	Sim	1,15
			3	Não	1,27	Não	1,09	Não	1,20
			4	Não	1,17	Não	1,10	Não	1,08
	Milho 2013	K- Means	2	Sim	1,01	Não	0,96	Sim	1,35
			3	Não	1,22	Não	1,02	Não	1,56
			4	Não	1,02	Não	1,00	Não	1,63
		Fuzzy C- Means	2	Sim	1,01	Não	0,95	Sim	1,35
			3	Não	1,22	Não	1,00	Não	1,54
			4	Não	1,22	Não	1,04	Não	1,62
Média			15**	1,60	13**	1,58	16**	1,78	

ANOVA* – Diferença significativa a 95% entre todas as classes; ER – Eficiência Relativa; Média – média da eficiência relativa e quantidade de divisões que apresentaram diferença significativa na ANOVA (**)

5.9 Comparação de mapas temáticos

Foram calculados os índices de concordância Kappa e Tau, a fim de se realizar uma avaliação referente à concordância dos mapas, em função do tipo de interpolador utilizado. Foram realizadas as comparações entre ID x IDQ, ID x KRI e IDQ x KRI para as UM geradas com duas, três e quatro classes. Para área 1, safra da soja 2011/2012 (Tabela 27), pode-se verificar que a concordância entre os mapas diminuiu quando houve aumento do número de classes, mas com maior intensidade com o método Fuzzy C-Means. Para o método K-Means, em todas as classes a concordância foi muito forte. Já para o método

Fuzzy C-Means, somente para 2 classes a concordância foi muito forte, sendo que para a divisão em 3 e 4 classes a concordância variou de média a muito forte.

Na safra 2012/2013, para a divisão em duas classes houve pouca diferença entre os mapas, sendo que para todas as comparações realizadas os mapas apresentaram concordância classificada como muito forte. Quando as UM foram geradas com três classes utilizando o método K-Means os mapas interpolados por IDQ apresentaram concordância fraca com ID e KRI.

Tabela 27 Índices Kappa e Tau extraídos da comparação entre mapas gerados por diferentes interpoladores área 1

Safra	Método	Nº	Interpoladores	Kappa	Tau
Soja 2011/ 2012	K-Means	2	ID x IDQ	0,96(MF)	0,96(MF)
			ID x krigagem	0,92(MF)	0,92(MF)
			IDQ x krigagem	0,94 (MF)	0,94(MF)
		3	ID x IDQ	0,91 (MF)	0,87(MF)
			ID x krigagem	0,89(MF)	0,85(MF)
			IDQ x krigagem	0,94(MF)	0,92(MF)
		4	ID x IDQ	0,90(MF)	0,84(MF)
			ID x krigagem	0,88(MF)	0,81(MF)
			IDQ x krigagem	0,90(MF)	0,85(MF)
	Fuzzy C-Means	2	ID x IDQ	1,00(MF)	1,00(MF)
			ID x krigagem	0,94(MF)	0,94(MF)
			IDQ x krigagem	0,94(MF)	0,94(MF)
		3	ID x IDQ	0,54(M)	0,39(Fr)
			ID x krigagem	0,56(M)	0,41(M)
			IDQ x krigagem	0,92(MF)	0,92(MF)
		4	ID x IDQ	0,73(F)	0,59(M)
			ID x krigagem	0,84(MF)	0,77(F)
			IDQ x krigagem	0,77(F)	0,65(F)
Soja 2012/ 2013	K-Means	2	ID x IDQ	0,96(MF)	0,96(MF)
			ID x krigagem	0,93(MF)	0,93(MF)
			IDQ x krigagem	0,94(MF)	0,94(MF)
		3	ID x IDQ	0,29(Fr)	0,04(SC)
			ID x krigagem	0,93(MF)	0,92(MF)
			IDQ x krigagem	0,27(Fr)	0,01(SC)
		4	ID x IDQ	0,87(MF)	0,81(MF)
			ID x krigagem	0,90(MF)	0,86(MF)
			IDQ x krigagem	0,87(MF)	0,82(MF)
	Fuzzy C-Means	2	ID x IDQ	0,96(MF)	0,96(MF)
			ID x krigagem	0,93(MF)	0,93(MF)
			IDQ x krigagem	0,94(MF)	0,94(MF)
		3	ID x IDQ	0,89(MF)	0,86(MF)
			ID x krigagem	0,91 (MF)	0,88(MF)
			IDQ x krigagem	0,91 (MF)	0,88(MF)
		4	ID x IDQ	0,78(F)	0,68(F)
			ID x krigagem	0,89(MF)	0,84(MF)
			IDQ x krigagem	0,80(F)	0,71(F)

Método – método de agrupamento; Nº – número de classes; Concordância – fraca (Fr); moderada (M); forte (F); muito forte (MF)

Para as UM geradas para safra da soja na área 2 (Tabela 28), na divisão em duas classes os mapas gerados pelos três interpoladores apresentaram concordância classificada como muito forte. Quando as UM foram geradas com três classes a partir do método K-Means, os mapas apresentaram as maiores diferenças entre o interpolador IDQ em comparação com os demais, sendo que estas comparações se apresentaram sem concordância. De modo geral, a concordância entre os mapas foi menor quando as UM foram geradas a partir do método K-Means, com duas classes, e Fuzzy C-Means, com quatro classes.

Tabela 28 Índices Kappa e Tau extraídos da comparação entre mapas gerados por diferentes interpoladores área 2

Safra	Método	Nº	Interpoladores	Kappa	Tau
Soja 2012/ 2013	K-Means	2	ID x IDQ	0,90(MF)	0,92(MF)
			ID x krigagem	0,95(MF)	0,96(MF)
			IDQ x krigagem	0,88(MF)	0,91(MF)
		3	ID x IDQ	0,09(SC)	0,01(SC)
			ID x krigagem	0,90(MF)	0,89(MF)
			IDQ x krigagem	0,10(SC)	0,01(SC)
		4	ID x IDQ	0,74(F)	0,63(F)
			ID x krigagem	0,82(MF)	0,74(F)
			IDQ x krigagem	0,65(F)	0,50(M)
	Fuzzy C-Means	2	ID x IDQ	0,86(MF)	0,87(MF)
			ID x krigagem	0,93(MF)	0,93(MF)
			IDQ x krigagem	0,84(MF)	0,86(MF)
		3	ID x IDQ	0,68(F)	0,58(M)
			ID x krigagem	0,85(MF)	0,80(F)
			IDQ x krigagem	0,63(F)	0,51(M)
		4	ID x IDQ	0,59(M)	0,40(Fr)
ID x krigagem	0,79(F)		0,69(F)		
IDQ x krigagem	0,55(M)		0,35(Fr)		
Milho 2013	K-Means	2	ID x IDQ	0,78(F)	0,78(F)
			ID x krigagem	0,57(M)	0,57(M)
			IDQ x krigagem	0,47(M)	0,47(M)
		3	ID x IDQ	0,75(F)	0,68(F)
			ID x krigagem	0,72(F)	0,65(F)
			IDQ x Krigagem	0,62(F)	0,50(M)
		4	ID x IDQ	0,37(Fr)	0,09(SC)
			ID x krigagem	0,36(Fr)	0,04(SC)
			IDQ x krigagem	0,40(Fr)	0,11(SC)
	Fuzzy C-Means	2	ID x IDQ	0,80(F)	0,80(F)
			ID x krigagem	0,57(M)	0,57(M)
			IDQ x krigagem	0,46(M)	0,46(M)
		3	ID x IDQ	0,76(F)	0,69(F)
			ID x krigagem	0,71(F)	0,63(F)
			IDQ x krigagem	0,62(F)	0,51(M)
		4	ID x IDQ	0,31(Fr)	-0,03(Fr)
ID x krigagem	0,60(M)		0,40(Fr)		
IDQ x krigagem	0,42(M)		0,14(SC)		

Método – método de agrupamento; N° – número de classes; Concordância – sem concordância; fraca (Fr); moderada (M); forte (F); muito forte (MF)

Quando comparados os mapas das UM geradas para safra do milho, para a divisão em duas classes os mapas foram classificados com concordância variando de forte a moderada. Nas UM geradas com três classes, os mapas apresentaram concordância forte para todas as comparações, exceto ID x krigagem, considerando o índice Tau que apresentou concordância moderada. Quando comparados os mapas gerados com quatro classes pelo algoritmo K-Means, todas as comparações apresentaram valores classificados como de fraco a sem concordância.

Tabela 29 Índices Kappa e Tau extraídos da comparação entre mapas gerados pelos métodos de agrupamento K-Means e Fuzzy C-Means área 1

Índices de concordância entre os métodos de agrupamento K-Means e Fuzzy C-Means				
Safra	Nº	Método	Kappa	Tau
Soja 2011/ 2012	2	ID	0,96(MF)	0,96(MF)
		IDQ	0,99(MF)	0,99(MF)
		KRI	0,99(MF)	0,99(MF)
	3	ID	0,99(MF)	0,99(MF)
		IDQ	0,53(M)	0,38(Fr)
		KRI	0,55(M)	0,41(M)
	4	ID	0,99(MF)	0,98(MF)
		IDQ	0,71(F)	0,57(M)
		KRI	0,91(MF)	0,87(MF)
Soja 2012/ 2013	2	ID	0,99(MF)	0,99(MF)
		IDQ	0,98(MF)	0,98(MF)
		KRI	0,98(MF)	0,98(MF)
	3	ID	0,35(Fr)	0,12(SC)
		IDQ	0,85(MF)	0,80(F)
		KRI	0,34(Fr)	0,12(SC)
	4	ID	0,48(M)	0,20(SC)
		IDQ	0,27(Fr)	-0,01(SC)
		KRI	0,42(M)	0,13(SC)

Método – método de interpolação; Nº – número de classes; Concordância – sem concordância; fraca (Fr); moderada (M); forte (F); muito forte (MF)

Foram calculados também os índices de concordância Kappa e Tau, a fim de se realizar uma avaliação referente à concordância dos mapas, em função do método de agrupamento utilizado na etapa de geração das UM. Foram realizadas as comparações entre K-Means e Fuzzy C-Means para as UM geradas com duas, três e quatro classes e com os interpoladores ID, IDQ e krigagem. Os mapas gerados para área 1, safra da soja 2011/2012, com duas classes (Figura 29), apresentaram concordância classificada como muito forte, segundo os índices Kappa e Tau. As classificações em três e quatro classes apresentaram concordância classificada como muito forte a moderada, exceto para a comparação do mapa gerado com o interpolador IDQ com três classes, que apresentou concordância fraca.

Os mapas gerados para safra 2012/2013 para área 1 com duas classes apresentaram concordância classificada como muito forte. Quando comparados os mapas gerados com três classes, a concordância variou de muito forte para os mapas gerados com dados interpolados por IDQ e sem concordância para os mapas gerados por ID e krigagem. Os mapas gerados com quatro classes apresentaram concordância classificada de moderada a sem concordância.

Os mapas gerados pelos métodos de agrupamento K-Means e Fuzzy C-Means para área 2, safra da soja 2012/2013, com duas classes (Figura 30), apresentaram concordância variando de muito forte a forte, segundo os índices Kappa e Tau. Quando comparados os mapas gerados com duas e quatro classes, a concordância variou de moderada a sem concordância.

Os mapas gerados para safra do milho 2013 apresentaram concordância muito forte para as UM geradas com duas e três classes. Quando comparados os mapas gerados com quatro classes, a concordância foi classificada como muito forte, exceto para os mapas gerados com dados interpolados por ID, que apresentaram concordância média segundo o Kappa e fraca para o Tau.

Tabela 30 Índices Kappa e Tau extraídos da comparação entre mapas gerados por K-Means e Fuzzy C-Means área 2 safra da soja 2012/2013

Índices de concordância entre os métodos de agrupamento K-Means e Fuzzy C-Means				
Safra	Nº	Método	Kappa	Tau
Soja 2012/ 2013	2	ID	0,86(MF)	0,88(MF)
		IDQ	0,77(F)	0,80(F)
		KRI	0,87(MF)	0,89(MF)
	3	ID	0,02(SC)	-0,31(SC)
		IDQ	0,57(M)	0,47(M)
		KRI	0,03(SC)	-0,30(SC)
	4	ID	0,70(F)	0,56(M)
		IDQ	0,34(Fr)	0,07(SC)
		KRI	0,62(F)	0,43(M)
Milho 2013	2	ID	1,00(MF)	1,00(MF)
		IDQ	0,93(MF)	0,93(MF)
		KRI	0,99(MF)	0,99(MF)
	3	ID	0,94(MF)	0,93(MF)
		IDQ	0,94(MF)	0,92(MF)
		KRI	0,97(MF)	0,96(MF)
	4	ID	0,52(M)	0,30(Fr)
		IDQ	0,94(MF)	0,91(MF)
		KRI	0,97(MF)	0,95(MF)

Método – método de interpolação; Nº – número de classes; Concordância – sem concordância (SC); fraca (Fr); moderada (M); forte (F); muito forte (MF)

6 CONCLUSÕES

A altitude foi o atributo que maior e mais se correlacionou espacialmente com a produtividade da soja e do milho em ambas as áreas, estando presente em quase todas as unidade de manejo geradas.

Em todos os casos, verificou-se que a seleção dos atributos foi válida, pois permitiu a divisão da área em pelo menos duas sub-regiões com potencial produtivo distinto, sendo que na área 1 a divisão foi válida até quando a divisão foi realizada em 3 e 4 classes.

Os interpoladores ID e krigagem apresentaram UM similares, visto que as menores e maiores médias de diferença foram de 5 e 9% respectivamente.

A concordância entre os mapas diminuiu quando houve aumento do número de classes, mas com maior intensidade com o método Fuzzy C-Means.

Os algoritmos de agrupamento K-Means e Fuzzy C-Means se apresentaram similares na divisão em 2 UM.

O melhor método de interpolação foi a krigagem, seguida do ID, justificando-se a escolha do interpolador mais robusto (krigagem) na geração de UM.

7 REFERÊNCIAS

- ALVES, E. D. L.; VECCHIA, F. A. S. Análise de diferentes métodos de interpolação para a precipitação pluvial no Estado de Goiás. **Revista Acta Scientiarum**, Maringá, v. 33, n. 2, p.193-197, 2011.
- AMADO, T. J. C.; BELLÉ, G. L.; DELLAMEA, R. B. C.; PES, L. Z.; FULBER, R.; PIZZUTI, L.; SCHENATO, R. B.; LEMAINSKI, C. L. Projeto Aquarius-Cotrijal: polo de agricultura de precisão. **Revista Plantio Direto**, Passo Fundo, n. 91, p. 1-10, 2006.
- AMORIN, A. O. **Evolução do uso e ocupação da terra na área de proteção ambiental João Leite - GO**. 2009. 95 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual de Goiás, Anápolis, 2009.
- ANDRIOTTI, J. L. S. Notas de geoestatística. **Acta Geologica Leopoldensia**, São Leopoldo, n. 25, p. 3-14, 2002.
- ANGELICO, J. C. Desempenho da co-krigagem na determinação da variabilidade de atributos do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 30, n. 6, p. 931-936, 2006.
- ANTUNES, A. F.; LINGNAU, C. Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital. In: CONGRESSO E FEIRA PARA USUÁRIOS DE GEOPROCESSAMENTO DA AMÉRICA LATINA, 2., 1997, Curitiba. **Anais...** Curitiba: GIS Brasil, 1997.
- BALESDENT, J.; CHENU, C.; BALABANE, M. Relationship of soil organic matter dynamics to physical protection and tillage. **Soil Till Res**, v. 53, p. 215-230, 2000.
- BARROS, L. C.; BASSANEZI, R. C. **Tópicos de lógica fuzzy e biomatemática**. 2. ed. Campinas: IMECC, 2010. 344 p.
- BAZZI, C. L. **Software para definição e avaliação de unidades de manejo em agricultura de precisão**. 2011. 123 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel, 2011.
- BAZZI, C. L.; SOUZA, E. G. de; QUEIROZ, F. N.; SANTOS, D. KONOPATZKI, M. R. S. Influência do tipo de interpolador em mapas de resistência a penetração. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2010, Ribeirão Preto. **Anais...** Ribeirão Preto: CONBAP, 2010.
- BAZZI, C. L.; SOUZA, E.G. de; URIBE-OPAZO, M. A.; SANTOS, D.; KONOPATZKI, M. R. S. Uso da validação cruzada na seleção de modelos de semivariogramas. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 38., 2009, Petrolina/Juazeiro. **Anais...** Petrolina/Juazeiro: CONBEA, 2009. p.1-4.
- BAZZI, C. L.; SOUZA, E. G.; URIBE-OPAZO, M. A.; NOBREGA, L. H. P; ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, v. 33, p. 1-14, 2013.
- BEZDEK, J. C. **Patter recognition with fuzzy objective function algorithms**. New York: Plenum Press, 1981. 256 p.
- BONHAM C. D.; REICH R. M; LEADER K. K. Spatial cross-correlation of *Bouteloua gracilis* with site factors. **Grassland Science**, Nasushiobara, v. 41, n. 1, p. 196-201, 1995.

BORGES, V. R. P. Comparação entre as técnicas de agrupamento K-Means e Fuzzy C-Means para segmentação de imagens coloridas. In: ECONTRON ANUAL DE COMPUTAÇÃO, 8., 2010, Catalão. **Anais...** ENACOMP: Catalão, 2010.

BOTTEGA, E. L.; QUEIROZ, D. M. de; PINTO, F. A. C.; SOUZA, C. M. A. de. Variabilidade espacial de atributos do solo em sistema de semeadura direta com rotação de culturas no cerrado brasileiro. **Ciência Agrônômica**, v. 44, n. 1, p. 1-9, 2013.

BRANDÃO, S. L.; LIMA, S. C. pH e condutividade elétrica em solução do solo, em áreas de pinus e cerrado na chapada, em Uberlândia (MG). **Caminhos de Geografia**, Uberlândia, v. 3, n. 6, p. 46-56, 2002.

BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** Salvador: INPE, 1996, p. 813-821.

CÂMARA, G. **Modelos, linguagens e arquiteturas para banco de dados geográficos**. 1995. 264 f. Tese (Doutorado em Geoprocessamento) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995.

CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURVO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of American Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.

CANARACHE, A. PENETR – a generalized semi-empirical model estimating soil resistance to penetration. **Soil & Tillage Research**, Amsterdam, v. 16, p. 51-70, 1990.

CARVALHO, J. R. P.; ASSAD, E. D. Análise espacial da precipitação pluviométrica no Estado de São Paulo: comparação de métodos de interpolação. **Engenharia Agrícola**, Jaboticabal, v. 25, n. 2, p. 377-384, 2005.

CARVALHO, J. R. P. de; SILVEIRA, P. M. da; VIEIRA, S. R. Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. **Pesquisa Agropecuária Brasileira**, Brasília, v. 37, n. 8, p. 1151-9, 2002.

CARVALHO, M. P.; TAKEDA E.Y; FREDDI, O. S. Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP). **Revista Brasileira de Ciência do Solo**, Viçosa, v. 27, n. 4, p. 695-703, 2003.

CAVALCANTE, E. G. S.; ALVES, M. C.; SOUZA, Z. M.; PEREIRA, G. T. Variabilidade espacial de atributos químicos do solo sob diferentes usos e manejos. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, n. 6, p. 1329-1339, 2007.

CAVALCANTE, E. G. S.; ALVES, M. C.; SOUZA, Z. M. de; PEREIRA, G. T. Variabilidade espacial de atributos físicos do solo sob diferentes usos e manejos. **Engenharia Agrícola e Ambiental**, Campina Grande, v. 15, n. 3, p. 237-243, 2011.

COELHO, E. C.; SOUZA, E.G. de; URIBE-OPAZO, M. A.; PINHEIRO NETO, R. Influência da densidade amostral e do tipo de interpolador na elaboração de mapas temáticos. **Acta Scientiarum**, Maringá, v. 31, n. 1, p. 165-174, 2009.

COHEN J. A. Coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, Califórnia, v. 20, n. 1, p. 37-46, 1960.

CONAB – Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: grãos, primeiro levantamento – Intenção de plantio.** Brasília: CONAB, 2013a. 28 p.

CONAB – Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: grãos, quinto levantamento.** Brasília: CONAB, 2013b. 28 p.

CONGALTON, R. G.; GREEN, K. A practical look at sources of confusion in error matrix generation. **Photogrammetric Engineering And Remote Sensing**, Reston, v. 59, n. 5, p. 641-644, 1993.

COSTA, J. M.; OLIVEIRA, E. F. de. **Fertilidade do solo e nutrição de plantas: culturas: soja-milho-trigo-algodão-feijão.** 2. ed. Campo Mourão: COAMO, Cascavel: COODETEC, 2001. 93 p.

COSTA NETO, P. R.; ROSSI, L. F. S. ZAGONEL, G. F.; RAMOS, L. P. Produção de biocombustível alternativo ao óleo diesel através da transesterificação de óleo de soja usado em fritura. **Revista Química Nova**, São Paulo, v. 23, n. 4, p. 531-537, 2000.

CRESSIE, N. A. Fitting variogram models by weighted least squares. **Mathematical Geology**, New York, v. 17, n. 4, p. 563-586, 1985.

CRESSIE, N. A. **Statistics for spatial data.** New York: John Wiley & Sons, 1993. 900 p.

DAFONTE, J. D.; GUITIÁN, M. U.; PAZ-FERREIRO, J.; SIQUEIRA, G. M.; VÁZQUEZ, E. V. Mapping of soil micronutrientes in an European Atlantic agricultural landscape using ordinary kriging and indicator approach. **Bragantia**, Campinas, v. 69, p. 175-186, 2010.

DALBIANCO, L. **Variabilidade espacial e estimativa da condutividade hidráulica e caracterização físico-hídrica de uma microbacia rural.** 2009. 115 f. Dissertação (Mestrado em Ciência do solo) – Universidade Federal de Santa Maria, Santa Maria, 2009.

DALCHIAVON, F. C.; CARVALHO, M. P.; ANDREOTTI, M.; MONTANARI, R. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho Distroférico sob sistema plantio direto. **Ciência Agrônômica**, v. 43, n. 3, p. 453-461, 2012.

D'ANDRÉA, A. F.; SILVA, M. L. N.; CURTI, N.; FERREIRA, M. M. Atributos de agregação indicadores da qualidade do solo em sistemas de manejo na região dos Cerrados no Sul do Estado de Goiás. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 26, n. 4, p. 1047-1054, 2002.

DEXTER, A. R.; YOUNGS, I. M. Soil physic toward 2000. **Soil Tillage Research**, Amsterdam, v. 24, p. 101-106, 1992.

DOBERMANN, A.; PING, J. L. Geostatistical integration of yield monitor data and remote sensing improves yield maps. **Agronomy Journal**, Madison, v. 96, n. 1, p. 285-297, 2004.

DOBERMANN, A.; PING, J. L.; ADAMCHUK, V. I.; SIMBAHAN, G. C.; FERGUSON, R. B. Classification of crop yield variability in irrigated production fields. **Agronomy Journal**, Madison, v. 95, n. 1, p. 1105-1120, 2003.

DOERGE, T. A. **Site-specific management guidelines.** Norcross: Potash & Phosphate Institute, 2000. 135 p.

DUARTE, J. O. **Introdução e importância econômica do milho.** Sete Lagoas: Embrapa Milho e Sorgo, 2002.

EGUCHI, E. S.; SILVA, E. L. da; OLIVEIRA, M. S. de. Variabilidade espacial da textura e da densidade de partículas em um solo aluvial no Município de Lavras, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 6, n. 2, p. 242-246, 2002.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Manual de métodos de análise de solo**. 2. ed. Rio de Janeiro: EMBRAPA-CNPS, 1997. 212 p.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solo**. Rio de Janeiro: CNPSO, 2006. 412 p.

FARACO, M. A.; URIBE-OPAZO, M. A.; SILVA, E. A. A.; JOHANN, J. A.; BORSSOI, J. A. Seleção de modelos de variabilidade espacial para elaboração de mapas temáticos de atributos físicos do solo e produtividade da soja. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 32, n. 2, p. 463-476, 2008.

FERRAZ, G. A. E. S.; SILVA, F. M. da; COSTA, P. A. N. da; SILVA, A. C.; CARVALHO, F. M. Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira. **Coffee Science**, Lavras, v. 7, n. 1, p. 59-67, 2012.

FIGUEIREDO, C. C.; RAMOS, M. L. G; TOSTES, R. Propriedades físicas e matéria orgânica de um Latossolo Vermelho sob sistemas de manejo e cerrado nativo. **Bioscience Journal**, Uberlândia, v. 24, n. 3, p. 24-30, 2008.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de exatidão global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2007, Florianópolis. **Anais...** Florianópolis: SBSR, 2007. p. 5755-5762.

FLEMING, K. L.; WESTFALL, D. G. Evaluating farmer defined management zone maps for variable rate fertilizer application. **Precision Agriculture**, v. 2, n. 2, p. 201-215, 2000.

FOODY, G. M. On the compensation for chance agreement in image classification accuracy assessment. **Photogrammetric Engineering and Remote Sensing**, Reston, v. 58, n. 10, p. 1459-1460, 1992.

FRAISSE, C. W.; SUDDUTH, K. A.; KITCHEN, J. R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **International Journal of the American Society of Agricultural and Biological Engineers**, Joseph, v. 1, n. 44, p. 155-166, 2001.

FURTINI NETO, A. E.; VALE, F. R, do; RESENDE, A. V.; GUEDES, G. A. A. **Fertilidade do solo**. Lavras: UFLA/FAEPE, 2001. 261 p.

GARDIMAN JUNIOR, B. S.; MAGALHÃES, I. A. L.; FREITAS, C. A. A.; CECILIO, R. A. Análise de técnicas de interpolação para espacialização da precipitação pluvial na bacia do rio Itapemirim (ES). **Revista Ambientia**, Guarapuava, v. 8, n. 1, p. 61-71, 2012.

GIMENEZ, L. M; MOLIN, J. P. Algoritmo para redução de erros em mapas de produtividade para agricultura de precisão. **Agrocomputação**, Ponta Grossa, v. 2, n. 1, p. 5-10, 2004.

GOMES, N. M.; FARIA, M. A.; SILVA, A. M. da; MELLO, C. R. de; VIOLA, M. R. Variabilidade espacial dos atributos físicos do solo associados ao uso e ocupação da paisagem. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 11, n. 4, p. 427-435, 2007.

HORNUNG, A.; KHOSLA, R.; REICH, R. M.; INMAN, D.; WESTFALL, D. G. Comparison of Site-Specific Management Zones: Soil-Color-Based and Yield-Based. **Agronomy Journal**, Madison, v. 98, n. 1, p. 407-415, 2006.

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

JAKOB, A. A. E.; YOUNG, A. F. O uso de métodos de interpolação espacial de dados nas análises sociodemográficas. In: ENCONTRO NACIONAL DE ESTUDOS POPULACIONAIS, 15., 2006, Caxambu. **Anais...** Caxambu: ENEP, 2006. p. 1-22.

JIPKATE, B. R.; GOHOKAR, V. V. A comparative analysis of Fuzzy C-Means clustering and K-Means clustering algorithms. **International Journal of Computational Engineering**, v. 2, n. 3, p. 737-739, 2012.

JONES, T. A. Skewness and kurtosis as criteria of normality in observed frequency distributions. *Journal Sedimentary Petrology*, Colorado, p. 1622-1627, 1969.

KHOSLA, R. Precision agriculture: challenges and opportunities in a flat world. In: WORLD CONGRESS OF SOIL SCIENCE, SOIL SOLUTIONS FOR A CHANGING WORLD, 19., 2010, Brisbane. **Anais...** Brisbane: WCSS, 2010. p. 26-28.

KIEHL, E. J. **Manual de edafologia**. São Paulo: Agronômica Ceres, 1979. 262 p.

KLEIN, V. A.; BASEGGIO, M.; MADALOSSO, T.; MARCOLIN, C. D. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. **Ciência Rural**, Santa Maria, v. 40, n. 7, p. 1550-1556, 2010.

KRAVCHENKO, A. N.; BULLOCK, D. G. A comparative study of interpretation methods for mapping properties. **Agronomy Journal**, Madison, v. 91, p. 393-400, 1999.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, Arlington, v. 33, n. 1, p. 159-174, 1977.

LEMONS, R. C.; SANTOS, R. D. **Manual de descrição e coleta de solo no campo**. Campinas: Sociedade Brasileira de Ciência do Solo, 1984. 46 p.

LIMA, A. F. **Desenvolvimento de métodos para o preparo de amostras de fertilizantes visando à determinação de cobre, cádmio e chumbo por espectrometria de absorção atômica com chama**. 2010. 66 f. Dissertação (Mestrado em Química) – Universidade Federal de Uberlândia, Uberlândia, 2010.

LIMA, J. S. S.; OLIVEIRA, R. B.; SILVA, S. Técnicas de agricultura de precisão aplicada a cultura do café conilon. **Estudos avançados em produção vegetal**, Vitória, v. 1, p. 179-197, 2008.

LUZ, N. C. **Algoritmos de clusterização como apoio à modelagem de preditores de sítios arqueológicos baseados em variáveis ambientais**. 2004. 87 f. Dissertação (Mestrado em Engenharia Elétrica e Computação) – Universidade Federal de Goiás, Goiânia, 2004.

MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. 2. ed. Piracicaba: POTAFOS, 1997. 319 p.

MAPA – Ministério da Agricultura, Pecuária e Abastecimento. **Regras para análise de sementes**. Ministério da Agricultura, Pecuária e Abastecimento. Brasília: Mapa/ACS, 2009. 399 p.

MAPA – Ministério da Agricultura, Pecuária e Abastecimento. **Soja**. Brasília: MAPA, 2013a.

MAPA – Ministério da Agricultura, Pecuária e Abastecimento. **Milho**. Brasília: MAPA, 2013b.

MA, Z.; REDMOND, R. L. Tau coefficient for accuracy assessment of classification of remote sensing data. **Photogrammetric Engineering and Remote Sensing**, Reston, v. 61, n. 4, p. 435-439, 1995.

MAZZINI, P. L. F.; SCHETTINI, C. A. F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase-sinópticos. **Brazilian Journal Aquatic Science Technology**, Itajaí, v. 13, n. 1, p. 53-64, 2009.

MELLO, C. R.; LIMA, J. M.; SILVA, A. M.; MELLO, J. M.; OLIVEIRA, M. S. Krigagem e inverso do quadrado da distância para interpolação dos parâmetros da equação de chuvas intensas. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 27, n. 5, p. 925-933, 2003.

MENDES, A. M. S.; FONTES, R. L. F.; OLIVEIRA, M. de. Variabilidade espacial da textura de dois solos do Deserto Salino, no Estado do Rio Grande do Norte. **Revista Ciência Agrônômica**, Ceará, v. 39, n. 1, p. 19-27, 2008.

MILANI, L.; SOUZA, E. G. de; URIBE-OPAZO, M. A.; GABRIEL FILHO, A.; JOHANN, J. A.; PEREIRA, J. O. Unidades de manejo a partir de dados de produtividade. **Acta Scientiarum Agronomy**, Maringá, v. 28, n. 4, p. 591-598, 2006.

MIRANDA, J. I. **Fundamentos de Sistemas de Informações Geográficas**. 2. ed. Brasília: Embrapa, 2010. 425 p.

MIRANDA, F. A.; FREITAS, S. R. C.; FAGGION, P. L. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. **Boletim de Ciências Geodésicas**, Curitiba, v. 15, n. 3, p. 428-443, 2009.

MOLIN, J. P. **Agricultura de precisão: o gerenciamento da variabilidade**. Piracicaba, 2003. 83 p.

MOLIN, J. P.; RABELLO, L. M. Estudos sobre a mensuração da condutividade elétrica do solo. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 1, p. 90-101, 2011.

MOLIN, J. P.; VIEIRA JUNIOR, P. A.; DOURADO NETO, D.; FAULIN, G. D. C.; MASCARIN, L. Variação espacial na produtividade de milho safrinha devido aos macronutrientes e à população de plantas. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 6, n. 3, p. 309-324, 2007.

MONTEZANO, Z. F.; CORAZZA, E. J.; MURAOKA, T. Variabilidade de nutrientes em plantas de milho cultivado em talhão manejado homoganeamente. **Bragantia**, Campinas, v. 67, n. 4, p. 969-976, 2008.

NEGREIROS, J.; COSTA, A. C.; PAINHO, M.; AGUILAR, F. M. Sistemas de Informação Geográfica Princípios de interpolador krigagem ordinária. **Journal of Applied Sciences**, v. 10, p. 852-867, 2010.

OLIVEIRA JÚNIOR, J. C. de; SOUZA, L. C. P.; MELO, V. F. Variabilidade de atributos físicos e químicos de solos da formação guabirotuba em diferentes unidades de

amostragem. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 34, n. 5, p. 1491-1502, 2010.

ORTEGA, R. A.; SANTIBÁÑEZ, O. A. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. **Computers and Electronics in Agriculture**, v. 58, p. 49-59, 2007.

PATERNIANI, E. Agricultura sustentável nos trópicos. **Revista Estudos Avançados**, São Paulo, v. 15, n. 43, p. 303-326, 2001.

PIMENTEL-GOMES, F.; GARCIA, C. H. **Estatística aplicada a experimentos agrônômicos e florestais**. Volume 11. Piracicaba: FEALQ, 2002. 309 p.

PONZONI, F. J.; REZENDE, A. C. P. Influência da resolução espacial de imagens orbitais na identificação de elementos das paisagem em Altamira-Pa. **Revista Árvore**, Viçosa, v. 26, n. 4, p. 403-410, 2002.

QUEIROZ-VOLTAN, R. B.; NOGUEIRA, S. S. S.; MIRANDA, M. A. C. Aspectos da estrutura da raiz e do desenvolvimento de plantas de soja em solos compactados. **Pesquisa Agropecuária Brasileira**, Goiânia, v. 35, n. 5, p. 929-938, 2000.

RAMIREZ-LOPEZ, L.; REINA-SANCHEZ, A.; CAMACHO-TAMAYO, J. H. Variabilidad espacial de atributos físicos de un Typic Haplustox de los Llanos Orientales de Colômbia. **Engenharia Agrícola**, Jaboticabal, v. 28, n. 1, p. 55-63, 2008.

REICHERT, J. M.; REINERT, D. J.; BRAIDA, J. A. Qualidade dos solos e sustentabilidade de sistemas agrícolas. **Revista Ciência & Ambiente**, Santa Maria, n. 27, p. 29-48, 2003.

REICHERT, J. M.; SANTOS, D. R. **Solos florestais: retenção e liberação de nutrientes**. Santa Maria: Universidade Federal de Santa Maria, 2009. p. 45-66.

REICHERT, J. M.; SILVA, L. S.; SANTOS, D. R. **Fluxo de nutrientes**. Santa Maria: Universidade Federal de Santa Maria, 2009. p. 67-80.

REYNIERS, M.; MAERTENS, K.; VRINDTS, E.; BAERDEMAEKER, J. Yield variability related to landscape properties of a loamy soil in central Belgium. **Soil and Tillage Research**, Amsterdam, v. 88, n. 1, p. 262-273, 2006.

ROCHA, J. V.; LAMPARELLI, R. A. C. Do trabalho de campo ao processamento de mapas: um caso prático de agricultura de precisão no Brasil. In: CONGRESSO E FEIRA PARA USUÁRIOS DE GEOPROCESSAMENTO DA AMÉRICA LATINA, 4., 1998, Curitiba. **Anais...** Curitiba: GIS BRASIL, 1998.

ROCHA, M. M.; LOURENCO, D. A.; LEITE, C. B. B. Aplicação de krigagem com correção do efeito de suavização em dados de potenciometria da cidade de Pereira Barreto - SP. **Geologia USP**, São Paulo, v. 7, n. 2, p. 37-48, 2007.

RODRIGUES JUNIOR, F. A.; VIEIRA, L. B.; QUEIROZ, D. M.; SANTOS, N. T. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 15, n. 8, p. 778-787, 2011.

RODRIGUES, J. B. T.; ZIMBACK, C. R. L. Delimitação de zonas de manejo através da análise e classificação de mapas de produtividade de milho e soja. **Energia na Agricultura**, Botucatu, v. 17, n. 1, p. 44-61, 2002.

RUSPINI, E. H. A new approach to clustering. **Information and Control**, San Antonio, v. 15, n. 1, p. 22-32, 1969.

SANO, E. E.; SANTOS, E. M.; MENESES, P. R. Análise de imagens do satélite alô-pulsar para o mapeamento de uso e cobertura da terra do distrito federal. **Geociências**, São Paulo, v. 28, n. 4, p. 441-451, 2009.

SANTOS, A. O.; MAZIERO, J. V. G.; CAVALLI, A. C.; VALERIANO, M. M.; OLIVEIRA, H. de; MORAES, J. F. L.; KIYOSHI, Y. Monitoramento localizado da produtividade de milho cultivado sob irrigação. **Engenharia Agrícola e Ambiental**, Campina Grande, v. 5, n. 1, p. 88-95, 2001.

SANTOS, A. O.; PALLONE FILHO, W. J.; UNGARO, M. R. G.; LINO, A. C. L.; RADIN, B. Prospecção de zonas potenciais para manejo diferenciado em agricultura de precisão utilizando-se padrões de solo-planta-clima. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 7, n. 3, p. 463-468, 2003.

SANTOS, D. dos; SOUZA, E. G. de; NÓBREGA, L. H. P.; BAZZI, C. L.; GONÇALVES JÚNIOR, A. C. Variabilidade espacial de atributos físicos de um Latossolo Vermelho após cultivo de soja. **Engenharia Agrícola e Ambiental**, Campina Grande, v. 16, n. 8, p. 843-848, 2012.

SANTOS, R. T.; SARAIVA, A. M.; MOLIN, J. P. Comparison of algorithms for delineating management zones. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 2012, Indianapolis. **Anais...** Indianápolis: ICPA, 2012.

SANTOS, P. A.; CARVALHO, M. P.; FREDDI, O. S.; KITAMURA, A. E. Correlação linear e espacial entre o rendimento de grãos do feijoeiro e a resistência mecânica à penetração em um Latossolo Vermelho Disfrófico. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, n. 2, p. 287-295, 2005.

SANTOS, P. C.; SANTANA, A. C.; BARROS, P. L. C. QUEIROZ, J. C. B.; VIEIRA, T. O. O emprego da geoestatística na determinação do tamanho "ótimo" de amostras aleatórias com vistas à obtenção de estimativas dos volumes dos fustes de espécies florestais em Paragominas, estado do Pará. **Acta Amazonica**, Manaus, v. 41, n. 2, p. 213-222, 2011.

SCHAFFRATH, V. R.; TORMENA, C. A.; FIDALSKI, J.; GONCALVES, A. C. A. Variabilidade e correlação espacial de propriedades físicas de solo sob plantio direto e preparo convencional. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 32, n. 4, p. 1369-1377, 2008.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHPERS, J. S.; JOHNSON, S. H.; LUCHIARI JUNIOR, A. Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. **Agronomy Journal**, Madison, v. 96, p. 195-203, 2004.

SILVA JÚNIOR, J. F.; SIQUEIRA, D. S.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Classificação numérica e modelo digital de elevação na caracterização espacial de atributos dos solos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 16, n. 4, p. 415-424, 2012.

SILVA NETO, S. P. da. **A evolução da produtividade da soja no Brasil**. Planaltina, 2011. Disponível em: <<http://www.cpac.embrapa.br/noticias/artigosmidia/publicados/335/>>. Acesso em: 23 mar. 2012.

SILVA, P. C. M. da; CHAVES, L. H. G. Avaliação e variabilidade espacial de fósforo, potássio e matéria orgânica em Alissolos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 5, n. 3, p. 431-436, 2001.

SILVA, S. A.; LIMA, J. S. S.; SOUZA, G. S. de; OLIVEIRA, R. B. de. Avaliação de interpoladores estatísticos e determinísticos na estimativa de atributos do solo em agricultura de precisão. **IDESIA**, Chile, v. 26, n. 2, p. 75-81, 2008.

SIMEPAR. Instituto Tecnológico SIMEPAR. 2013.

SIQUEIRA, G. M.; VIEIRA, S. R.; DECHEN, S. C. Variabilidade espacial da densidade e da porosidade de um Latossolo Vermelho Eutroférico sob semeadura direta por vinte anos. **Bragantia**, Campinas, v. 68, n. 3, p. 751-759, 2009.

SHRIVASTAVA, R.; UPADHYAY, K.; BHATI, R.; MISHRA, D. K. Comparison between K-Means and C-Means clustering for CBIR. In: INTERNACIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE, 2., 2010, Washington. **Proceedings...** Washington: Computer Society, 2010. p. 117-118.

SOUZA, G. S. de; LIMA, J. S. de S.; XAVIER, A. C.; ROCHA, W. S. D. da. Krigagem ordinária e inverso do quadrado da distância aplicados na espacialização de atributos químicos de um argissolo. **Scientia Agrária**, Curitiba, v. 11, n. 1, p. 73-81, 2010a.

SOUZA, Z. M. de; CERRI, D. G. P.; COLET, M. J.; RODRIGUES, L. H. A.; MAGALHÃES, P. S. G.; MANDONI, R. J. A. Análise dos atributos do solo e da produtividade da cultura de cana-de-açúcar com o uso da geoestatística e árvore de decisão. **Ciência Rural**, Santa Maria, v. 40, n. 4, p. 840-847, 2010b.

SOUZA, Z. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; BARBIERI, D. M. Variabilidade espacial da textura de um Latossolo Vermelho eutroférico sob cultivo de cana-de-açúcar. **Engenharia Agrícola**, Jaboticabal, v. 24, n. 2, p. 309-319, 2004.

SPERANZA, E. A. **Métodos e ferramentas de interpolação para geração de mapas georreferenciados para tomada de decisão em irrigação de precisão**. 2008. 115 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade São Paulo, São Carlos, 2008.

TAYLOR, J. C.; WOOD, G. A.; EARL, R.; GODWIN, R. J. Soil factors and their influence on within-field crop variability, Part II: spatial analysis and determination of management zones. **Biosystems Engineering**, v. 84, n. 4, p. 441-453, 2003.

TEIXEIRA, L. A. J.; QUAGGIO, J. A.; MELLIS, E. V. Ganhos de eficiência fertilizante em bananeira sob irrigação e fertirrigação. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 33, n. 1, p. 272-278, 2011.

TEIXEIRA, M. B. R.; SCALON, J. D. Comparação entre estimadores de semivariância. **Revista Brasileira Biom**, São Paulo, v. 31, n. 2, p. 248-269, 2013.

TIEPPO, R. C.; SOUZA, E. G.; URIBE-OPAZO, M. A.; SILVEIRA, J. C. M. Avaliação de diferentes interpoladores na geração de mapas temáticos da produtividade de soja em agricultura de precisão. In: SIMPÓSIO INTERNACIONAL DE AGRICULTURA DE PRECISÃO, 9., 2007, Viçosa. **Anais...** Viçosa: Simpósio Internacional de agricultura de precisão, 2007. p. 1-4.

TSCHIEDEL, M.; FERREIRA, M. F. Introdução à agricultura de precisão: conceitos e vantagens. **Ciência Rural**, Santa Maria, v. 32, n. 1, p. 159-163, 2002.

USDA – United States Department of Agriculture. **Soybeans: world supply and distribution.** USDA, 2013a.

USDA – United States Department of Agriculture. **United States: soybeans and products supply and distribution local marketing years.** USDA, 2013b.

VENTURIERI, A. **Segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização do uso da terra na Região de Tucuruí (PA).** 1996. 115 f. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal de Goiás, São José dos Campos, 1996.

VIEIRA, V. A. S.; MELLO, C. R. de; LIMA, J. M. de. Variabilidade espacial de atributos físicos do solo em uma microbacia hidrográfica. **Ciência e Agrotecnologia**, Lavras, v. 31, n. 5, p. 1477-1485, 2007.

WEBSTER, R.; OLIVER, M. A. **Statistical Methods in soil and land resource survey.** 1. ed. New York: Oxford University Press, 1990. 328 p.

WOLLENHAUPT, N. C.; WOLKONSKI, R. P.; CLAYTON M. K. Mapping soil test phosphorus and potassium for variable-rate fertilizer applications. **Journal of production agriculture**, Madison, v. 7, n. 4, p. 441-448, 1994.

XIANG, L. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agriculture Sciences**, Maryland, v. 6, n. 2, p. 180-188, 2007.

YAN, L.; ZHOU, S.; FENG, L.; HONG-YI, L. Delineation of sitespecific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, v. 56, n. 2, p. 174-186, 2007.

ZADEH, L. A. Fuzzy sets. **Information and control**, San Antonio, v. 8, n. 1, p. 338-353, 1965.