

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

RICARDO SOBJAK

**SELEÇÃO DE VARIÁVEIS PARA DEFINIÇÃO DE UNIDADES DE MANEJO ATRAVÉS DA
LÓGICA FUZZY C-MEANS**

CASCAVEL

2012

RICARDO SOBJAK

**SELEÇÃO DE VARIÁVEIS PARA DEFINIÇÃO DE UNIDADES DE MANEJO ATRAVÉS DA
LÓGICA FUZZY C-MEANS**

Dissertação de Mestrado 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 Engenharia de Sistemas Agroindustriais.

Orientador: Eduardo Godoy de Souza
Co-orientador: Miguel Angel Uribe Opazo

CASCADEL – PARANÁ – BRASIL

2012

Dados Internacionais de Catalogação-na-Publicação (CIP)
Biblioteca Central do Campus de Cascavel – Unioeste
Ficha catalográfica elaborada por Jeanine da Silva Barros CRB-9/1362

S659s Sobjak, Ricardo
 Seleção de variáveis para definição de unidades de manejo através
 da lógica fuzzy C-means. / Ricardo Sobjak — Cascavel, PR: UNIOESTE,
 2012.
 71 p. ; 30 cm.

 Orientador: Prof. Dr. Eduardo Godoy de Souza
 Coorientador: Prof. Dr. Miguel Angel Uribe Opazo
 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. Agricultura de precisão. 2. Correlação espacial. 3. Eficiência
 relativa. I. Universidade Estadual do Oeste do Paraná. II. Título.

CDD 21. ed. 631.3

RICARDO SOBJAK

**SELEÇÃO DE VARIÁVEIS PARA DEFINIÇÃO DE UNIDADES DE MANEJO ATRAVÉS DA
LÓGICA FUZZY C-MEANS**

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

Orientador: Prof^o. Dr. Eduardo Godoy de Souza
Centro de Ciências Exatas e Tecnológicas, UNIOESTE

Prof^o. Dr. Raimundo Pinheiro Neto
Centro de Ciências Agrárias, UEM

Prof^o. Dr. Divair Christ
Centro de Ciências Exatas e Tecnológicas, UNIOESTE

Cascavel, 09 de abril de 2012.

BIOGRAFIA RESUMIDA

Ricardo Sobjak, brasileiro, casado, natural de Medianeira/PR, filho de Sérgio Luis Sobjak e Alice Pugsley Sobjak.

Graduado no curso de Tecnologia em Informática pela Universidade Tecnológica Federal do Paraná – UTFPR, em 2008 e especialista no curso de Projeto e Desenvolvimento de Sistemas Baseados em Objetos para Ambiente Internet pela UTFPR, em 2009.

Possui experiência na área de desenvolvimento de sistemas e infraestrutura de TI. Trabalhou como técnico em tecnologia da informação na UTFPR, Campus Medianeira, no período de 2007 a 2011. Atualmente, é docente na área de informática, no Instituto Federal de Santa Catarina – IFSC, Campus Chapecó, desde janeiro de 2011.

Ingressou no curso de Mestrado em Engenharia Agrícola em março de 2010, pela Universidade Estadual do Oeste do Paraná – UNIOESTE, cuja área de concentração foi em Sistemas Agroindustriais, com temas relacionados à agricultura de precisão.

À minha esposa,
ao meu filho,
aos meus pais e meus irmãos,
dedico este trabalho com todo meu amor.

AGRADECIMENTOS

Agradeço a Deus pelo seu cuidado e sua presença em minha vida;

À minha esposa, Emanuela, meus pais, Sérgio e Alice, meus irmãos, Anderson e Rodrigo, e a todos da minha família pelo apoio, confiança e paciência;

À Universidade Estadual do Oeste do Paraná (UNIOESTE), pela oportunidade de participar do Programa de Mestrado e pela utilização de suas instalações;

Ao Professor Dr. Eduardo Godoy de Souza, pela orientação, confiança, pelos conselhos, amizade e apoio para a realização deste trabalho;

Ao Professor Dr. Miguel Angel Uribe Opazo, pelo auxílio e co-orientação deste trabalho;

Aos amigos e colegas de PGEAGRI: Nelson, Claudio, Davi, Eloi, Márcia e Flávio pelo apoio em todas as horas;

A todos os demais professores, colegas e funcionários que, direta ou indiretamente, participaram da realização deste trabalho.

SELEÇÃO DE VARIÁVEIS PARA DEFINIÇÃO DE UNIDADES DE MANEJO ATRAVÉS DA LÓGICA FUZZY C-MEANS

RESUMO

A área de produção agrícola contém informações importantes para se entender a resposta quanto à produtividade de uma cultura. A agricultura de precisão proporciona aos agricultores adquirirem e tratarem as variações encontradas na área de forma adequada. Unidades de manejo (UM) proporcionam a implantação da agricultura de precisão de forma viável e relativamente mais econômica, representando regiões homogêneas, que podem ser tratadas de forma diferenciada. Este trabalho consistiu em gerar unidades de manejo com diferentes números de variáveis através do algoritmo fuzzy C-means, baseando-se em atributos correlacionados espacialmente com a produtividade. O objetivo é avaliar a eficiência relativa de cada unidade de manejo e verificar se os diferentes modos de composição de variáveis se diferenciam na geração de UM. Geraram-se 15 delineamentos de UM, divididos de 2 a 5 classes, baseando-se nos atributos cobre, silte, argila e altitude, que foram correlacionados com a produtividade. A variável cobre teve a maior correlação espacial com a produtividade, a qual proporcionou a geração de UM com bons resultados de eficiência relativa e boa separação dos dados entre as classes. A eficiência relativa não se apresentou de forma ordenada, crescente ou decrescente, quanto ao número de variáveis utilizadas no delineamento em UM. A UM delineada a partir das variáveis Cu e argila, dividida em cinco classes, foi a que apresentou maior eficiência relativa.

Palavras-chave: agricultura de precisão, correlação espacial, eficiência relativa.

SELECTION OF VARIABLES FOR DEFINITION OF MANAGEMENT UNITS BY FUZZY C-MEANS LOGIC

ABSTRACT

The agricultural production area has important information to understand the response of a crop yield. Precision agriculture helps the farmers on acquiring and treating in correct way the variations found in the area. Management zones (MZ) provide the precision agriculture implementation in a viable and relatively economical way, since they represent homogeneous regions, which can be treated differently. Thus, this trial aimed at generating MZ with different numbers of variables using fuzzy C-means algorithm, based on attributes spatially correlated with crop yield. The objective was to evaluate the relative efficiency of each management zone and verify if the different ways of variable compositions differ in the generation of MZ. Fifteen designs of MZ were generated and divided from two to five classes, based on attributes as: copper, silt, clay and altitude, which were correlated with crop yield. The copper variable showed the highest spatial correlation with crop yield, which promoted the generation of MZ with good results of relative efficiency and good separation of data among the classes. The relative efficiency did not present in an orderly manner, increasing or decreasing according to the number of variables used in division of MZ. The delineated MZ was based on variables as copper and clay and divided into five classes, so, it showed the highest relative efficiency.

Keywords: precision agriculture, spatial correlation, relative efficiency.

SUMÁRIO

LISTA DE TABELAS	viii
LISTA DE FIGURAS	ix
LISTA DE ABREVIATURAS E SIGLAS	xi
1 INTRODUÇÃO	1
2 OBJETIVOS	3
2.1 Objetivo geral	3
2.2 Objetivos específicos.....	3
3 REVISÃO BIBLIOGRÁFICA	4
3.1 Soja.....	4
3.2 Solo.....	5
3.2.1 Atributos químicos de solo	5
3.2.2 Textura do solo	6
3.2.3 Topografia.....	6
3.3 Agricultura de precisão.....	6
3.4 Mapas temáticos	8
3.4.1 Construção de mapas temáticos	9
3.4.2 Comparação de mapas temáticos com o índice Kappa.....	9
3.5 Correlação espacial.....	10
3.6 Fuzzy C-means	13
3.6.1 Validação de clusters	15
3.7 Unidades de Manejo.....	16
4 MATERIAL E MÉTODOS	19
4.1 Localização da área experimental	19
4.2 Coleta dos dados	20
4.3 Análise exploratória dos dados.....	21
4.4 Análise de autocorrelação e correlação espacial entre variáveis	22
4.5 Interpolação dos dados	22
4.6 Normalização dos dados	23
4.7 Delimitação das unidades de manejo	23
4.8 Avaliação das unidades de manejo	24
5 RESULTADOS E DISCUSSÃO	26
5.1 Análise exploratória dos dados.....	26
5.2 Análise de correlação espacial entre variáveis	29
5.3 Delineamento das unidades de manejo.....	31
5.4 Avaliação das unidades de manejo	36
6 CONCLUSÕES	47
7 REFERÊNCIAS	48
ANEXOS	54
ANEXO A – Boxplots da produtividade dentro das classes de UM	55

LISTA DE TABELAS

Tabela 1	Estatística descritiva dos dados	26
Tabela 2	Matriz de correlação espacial das variáveis analisadas na área de estudo...	30
Tabela 3	Combinação de variáveis para gerar unidades de manejo	31
Tabela 4	Grupos de unidades de manejo semelhantes visualmente.....	36
Tabela 5	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 01-CuSiAlAr	37
Tabela 6	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 02-CuSiAl	38
Tabela 7	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 03-CuSi.....	38
Tabela 8	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 04-Cu.....	39
Tabela 9	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 05-CuSiAr	39
Tabela 10	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 06-CuAlAr	39
Tabela 11	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 07-SiAlAr	40
Tabela 12	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 08-CuAl.....	40
Tabela 13	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 09-CuAr	40
Tabela 14	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 10-SiAl.....	41
Tabela 15	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 11-SiAr.....	41
Tabela 16	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 12-ArAl.....	41
Tabela 17	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 13-Si	42
Tabela 18	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 14-Al	42
Tabela 19	Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 15-Ar.....	42
Tabela 20	Índice Kappa entre os mapas de unidades de manejo, divididos em 2, 3, 4 e 5 classes nos delineamentos 01-CuSiAlAr, 02-CuSiAl, 03-CuSi, 04-Cu, 06-CuAlAr e 09-CuAr	46

LISTA DE FIGURAS

Figura 1	Localização da área experimental.....	19
Figura 2	Densidade amostral de 130 e 55 pontos sobre a área experimental.....	20
Figura 3	Espaçamento utilizado na coleta de amostras da produtividade de soja na área experimental.....	21
Figura 4	Boxplot das variáveis analisadas.....	28
Figura 5	Divisão da área em unidades de manejo com duas classes.....	32
Figura 6	Divisão da área em unidades de manejo com três classes.....	33
Figura 7	Divisão da área em unidades de manejo com quatro classes.....	34
Figura 8	Divisão da área em unidades de manejo com cinco classes.....	35
Figura 9	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 01-CuSiAlAr com 2, 3, 4 e 5 classes.....	38
Figura 10	Eficiência relativa nas unidades de manejo.....	43
Figura 11	Gráfico de desempenho das divisões em unidade de manejo apontado pelos índices FPI, MPE e ER, em ordem decrescente para a ER e ordem crescente para FPI e MPE.....	45
Figura 12	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 02-CuSiAl com 2, 3, 4 e 5 classes.....	55
Figura 13	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 03-CuSi com 2, 3, 4 e 5 classes.....	55
Figura 14	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 04-Cu com 2, 3, 4 e 5 classes.....	55
Figura 15	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 05-CuSiAr com 2, 3, 4 e 5 classes.....	56
Figura 16	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 06-CuAlAr com 2, 3, 4 e 5 classes.....	56
Figura 17	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 07-SiAlAr com 2, 3, 4 e 5 classes.....	56
Figura 18	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 08-CuAl com 2, 3, 4 e 5 classes.....	57
Figura 19	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 09-CuAr com 2, 3, 4 e 5 classes.....	57
Figura 20	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 10-SiAl com 2, 3, 4 e 5 classes.....	57
Figura 21	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 11-SiAr com 2, 3, 4 e 5 classes.....	58
Figura 22	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 12-ArAl com 2, 3, 4 e 5 classes.....	58
Figura 23	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 13-Si com 2, 3, 4 e 5 classes.....	58
Figura 24	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 14-Al com 2, 3, 4 e 5 classes.....	59

Figura 25	Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 15-Ar com 2, 3, 4 e 5 classes.	59
-----------	--	----

LISTA DE ABREVIATURAS E SIGLAS

Al	alumínio
ANOVA	análise de variância
AP	agricultura de precisão
B	boro
C	carbono
Ca	cálcio
Cl	cloro
COODETEC	Cooperativa Central de Pesquisa Agrícola
Cu	cobre
CV	coeficiente de variação
ER	eficiência relativa
FCM	fuzzy C-means
Fe	ferro
FPI	fuzziness performance index
GPS	global positioning system
ha	hectare
HSD	honest significant difference
IQD	inverso do quadrado da distância
K	potássio
Mg	magnésio
Mn	manganês
Mo	molibdênio
MPE	modified partition entropy
N	nitrogênio
P	fósforo
pH	potencial de hidrogênio
RSP	resistência do solo à penetração
SIG	sistemas de informação geográfica
UM	unidade de manejo
Zn	zinco

1 INTRODUÇÃO

No Brasil, são explorados diferentes sistemas de produção agrícola, em propriedades nas quais os fatores clima, solo e relevo variam intensamente. Ainda são poucos os agricultores que adquirem e exploram as informações sobre a área de plantio com o objetivo de tratar adequadamente as variações que causam influência sobre a produtividade de uma cultura, tais como atributos do solo, pragas, doenças, dentre outros. Portanto, é importante que os agricultores intensifiquem o uso de informações seguras e tecnologias adequadas e atuais para permanecerem globalmente competitivos.

A técnica da agricultura de precisão (AP) utiliza tecnologias de informação para tratar o cultivo agrícola baseando-se no princípio da variabilidade do solo e clima. A partir de dados específicos de áreas geograficamente referenciadas, implanta-se o processo de automação agrícola, dosando-se adequadamente os insumos. AP é uma prática de interferência a fim de que se estabeleçam condições ideais às espécies cultivadas na agricultura, sejam elas de ordem química, física ou biológica.

Um conhecimento prévio das características da área é frequentemente utilizado para a tomada de decisões na AP. O mapeamento do solo é feito através de amostragem em pontos georreferenciados para análise de atributos químicos e físicos do solo. As características são estudadas para realizar um manejo adequado do solo para melhor rendimento da cultura. A partir de dados amostrais, valores são estimados para a área total a partir de métodos estatísticos. É possível gerar mapas, por exemplo, que mostram explicitamente regiões com variação de produtividade de acordo com os dados estimados em toda a área. Como a produtividade é o fator determinante nas decisões de gerenciamento, estes mapas são importantes para auxiliar nas decisões de gerenciamento e manejo do campo.

A AP é um ramo de pesquisa relativamente recente na área agrícola, mas sua proposta de gerenciamento da lavoura, através da aplicação adequada de insumos, tem chamado a atenção de produtores pelos benefícios que são oferecidos. O campo é tratado de forma diferenciada em cada região, com vistas à redução do impacto ambiental, a uma possível redução de custos e à produtividade, que é a maior responsável pela aceitação das práticas da AP. Para viabilizar economicamente a adoção das práticas em AP, uma alternativa é definir unidades de manejo dentro da área produtiva, as quais representam uma combinação homogênea de fatores potenciais que afetam a produtividade. Dentro desse contexto, unidades de manejo referem-se a regiões geográficas subdivididas no campo, que possuem homogeneidade na capacidade produtiva, as quais podem estar correlacionadas com atributos do relevo e do solo, que influenciam na produtividade.

Metodologias para definir unidades de manejo podem ser encontradas em diferentes propostas desenvolvidas empiricamente. Dentre elas estão a utilização da topografia, o sensoriamento remoto, as fotografias aéreas, além da definição baseada na resposta da produtividade, sendo a mais difundida atualmente. Entretanto, afirmar que apenas os dados de produtividade são suficientes para gerar unidades de manejo de forma eficaz pode ser considerado um tanto tendencioso por alguns pesquisadores. Nesse sentido, considera-se que as informações sobre a variabilidade espacial do potencial produtivo do solo, aliadas à informação contida nos mapas de produtividade, possibilitam o sucesso na definição de unidades de manejo.

É importante estudar as variáveis que influenciam a produtividade, para que sejam selecionadas e levadas em consideração no processo de determinação de unidades de manejo. Critérios de seleção dessas variáveis podem estar ligados com a autocorrelação espacial de determinada variável (atributo) do solo, assim como a correlação espacial desta variável com a produtividade. Entretanto, algumas variáveis podem se correlacionar mais com a produtividade do que outras. Tem-se, portanto, que é de interesse investigar se a simples seleção das variáveis mais correlacionadas com a produtividade e que não sejam correlacionadas entre si (redundantes) irá proporcionar o delineamento de unidades de manejo mais eficazes.

2 OBJETIVOS

2.1 Objetivo geral

Selecionar variáveis para definição de unidades de manejo através da lógica fuzzy C-means.

2.2 Objetivos específicos

- Gerar unidades de manejo baseando-se na técnica de agrupamento fuzzy C-means, e construção de seus referidos mapas;
- Avaliar o desempenho das unidades de manejo geradas, a partir dos índices de eficiência relativa, análise de variância e boxplots;
- Verificar se a eficiência das unidades de manejo se diferencia quanto à utilização de diferentes números e combinações de variáveis.

3 REVISÃO BIBLIOGRÁFICA

3.1 Soja

A soja, cujo nome científico é *Glycine max (L.) Merrill*, é nativa da Ásia e considerada uma das culturas mais antigas daquela área. Com base na espécie conhecida como *Glycine ussuriensis*, provável progenitor da soja que é atualmente cultivada, a origem seria na China, nas regiões Norte e Central (COSTA, 1996).

A soja é uma planta herbácea pertencente à família das Leguminosas, subfamília das Papilionáceas e a tribo das Faseoláceas; é geralmente anual e raramente perene. O caule é ramoso, com 80 a 150 cm de comprimento. As folhas são longopeciadas, com três folíolos cordiformes, muito desenvolvidos e peludos na parte inferior. As flores, reunidas em cachos curtos, são axilares, sésseis, brancas, violáceas ou amarelas, conforme a variedade. As vagens, levemente arqueadas, subcomprimidas, peludas, têm de 1 a 5 sementes. As sementes lisas, ovoides, globosas ou elípticas possuem hilo quase sempre castanho, cuja coloração difere de acordo com a variedade. Há sementes brancas, amarelas, escuras, negras, vermelhas, vermelho-escuras, verdes, verde-amareladas ou matizadas. O comprimento varia entre 3 e 7 mm. O peso de 100 sementes varia entre 5 e 17 gramas, de acordo com a variedade (GOMES, 1976).

A cultura da soja ocupa papel importante na economia mundial, sendo cultivada em quase todas as partes do mundo. Ludwig et al. (2011) destacam que o Brasil é o segundo maior produtor mundial e o maior da América Latina. Dentre as culturas de grãos, a soja destaca-se no cenário nacional, sendo a primeira colocada em área plantada. Estima-se que na safra de 2010/2011 foram cultivados cerca de 24,1 milhões de hectares de soja, os quais produziram em torno de 74,9 milhões de toneladas de grãos (COMPANHIA NACIONAL DE ABASTECIMENTO, 2011).

Destacam-se dentro do cenário produtivo nacional na região Centro-Oeste, o Estado do Mato Grosso com a maior produção nacional, cuja safra 2010/2011 obteve um rendimento de 3190 kg ha⁻¹ numa área de aproximadamente 6,4 milhões de hectares e uma produção de 20,4 milhões de toneladas, e na região Sul, o Estado do Paraná, com produção acima de 15,4 milhões de toneladas e rendimento de 3360 kg ha⁻¹ numa área de aproximadamente 4,6 milhões de hectares (COMPANHIA NACIONAL DE ABASTECIMENTO, 2011).

De acordo com a Companhia Nacional de Abastecimento (2011), os preços médios de recebidos pela soja nas cidades de Sorriso-MT e Cascavel-PR situaram-se, na semana de 23 a 27 de maio de 2011, entre R\$ 37,80/60 kg e R\$ 45,06/60 kg, respectivamente. Os

bons resultados econômicos apresentados com essa cultura têm estimulado os produtores a investirem cada vez mais na utilização de novas tecnologias de manejo de tal cultura.

A cultura da soja apresenta alta plasticidade, ou seja, capacidade de se adaptar às condições ambientais e de manejo, por meio de modificações na morfologia da planta, da arquitetura e dos componentes do rendimento. Essas modificações podem estar relacionadas com a fertilidade do solo, população de plantas e com o espaçamento entre linhas (PIRES et al., 2000).

A soja se adapta melhor às temperaturas entre 20 °C e 30 °C, entretanto, a temperatura ideal para seu crescimento e desenvolvimento está em torno de 30 °C (EMBRAPA SOJA, 2008).

De acordo com Embrapa Soja (2008), a instalação adequada de lavoura em soja é influenciada por fatores determinantes que estão relacionados com a época de semeadura, distribuição dos fatores climáticos, operações de semeadura, características das cultivares e a qualidade da semente. Trabalhos vêm sendo desenvolvidos com a finalidade de se obter maior qualidade nas lavouras de soja, como Ludwig et al. (2011) que estudaram o comportamento de duas cultivares de soja utilizando diferentes populações de plantas por hectare. Na agricultura de precisão (AP), a soja também tem sido alvo de estudo em diferentes trabalhos (JOHANN et al., 2004; RACHID JUNIOR et al., 2006, SUSZEK et al., 2011).

3.2 Solo

O solo é a parte superficial intemperizada não consolidada da crosta terrestre, contendo matéria orgânica e seres vivos. Nele se desenvolvem os vegetais, que obtêm do solo, através das raízes, a água e os nutrientes (RAIJ, 1991).

O solo é considerado, do ponto de vista físico, como um sistema heterogêneo, constituído de fases sólida, líquida e gasosa (RAIJ, 1991). A fertilidade do solo é vital para a produtividade, mas um solo fértil não é necessariamente um solo produtivo. O solo possui fatores que podem causar influências na produtividade, sejam eles elementos químicos, físicos e até mesmo topográficos (LOPES, 1995).

3. 2. 1 Atributos químicos de solo

Os atributos químicos de solo, também chamados de nutrientes, se dividem em macronutrientes (primários e secundários) e micronutrientes. Os macronutrientes são assim chamados por serem absorvidos em grande quantidade pelas plantas. Os macronutrientes primários são normalmente os mais comercializados como adubos, e os que apresentam

custo mais elevado para o agricultor. Os micronutrientes são absorvidos em pequena quantidade pelas plantas. Se os micronutrientes estiverem no solo em quantidades muito maiores do que a planta precisa, podem ser considerados como tóxicos, prejudiciais a ela (LOPES, 1995; SERRAT et al., 2002).

Os macronutrientes classificados como primários são: nitrogênio (N), fósforo (P) e potássio (K), já os secundários são: cálcio (Ca), magnésio (Mg) e enxofre (S). Já os micronutrientes são: boro (B), zinco (Zn), manganês (Mn), ferro (Fe), cloro (Cl), molibdênio (Mo) e cobre (Cu).

Os nutrientes primários geralmente tornam-se deficientes no solo antes dos demais, porque as plantas os usam em quantidades relativamente grandes. Os nutrientes secundários e os micronutrientes são geralmente menos deficientes e usados em quantidades menores, mas são tão importantes quanto os nutrientes primários para uma adequada fertilidade do solo (LOPES, 1995).

3. 2. 2 Textura do solo

A textura do solo é determinada pela quantidade existente de areia, silte e argila. Quanto menor o tamanho das partículas, mais próximas de argilosa e quanto maior o tamanho das partículas, mais próxima de arenosa estará a textura (LOPES, 1995). É a propriedade física do solo que menos sofre alteração ao longo do tempo.

A textura é importante para o entendimento do comportamento e manejo do solo. Durante a classificação do solo em determinado local, a textura é, muitas vezes, a primeira e a mais importante propriedade a ser determinada, pois a partir da textura, muitas conclusões importantes podem ser tomadas.

3. 2. 3 Topografia

A topografia da área determina a quantidade de escoamento superficial e de erosão, haja vista levar os nutrientes do solo junto com a água. Quanto maior a declividade, mais necessário é manejo, conseqüentemente há um aumento de trabalho e dos custos dos equipamentos (LOPES, 1995).

3.3 Agricultura de precisão

A necessidade do aumento da eficiência de todos os setores da economia globalizada para manter a competitividade fez com que as empresas agrícolas pensassem em um sistema de gestão. A evolução da informática em geoprocessamento, sistemas de

posicionamento global, além de outras tecnologias, tem proporcionado à agricultura uma nova forma de enxergar a propriedade, deixando de visualizar somente uma, mas várias pequenas propriedades dentro da mesma (AHRENS; MIARA; AHRENS, 2007). Além disso, é importante considerar as produções agrícolas com ênfase no conceito de sustentabilidade e, nesse sentido, é fundamental o conhecimento das variações espaciais e temporais dos fatores de produção e o manejo das lavouras considerando essa variabilidade (MOLIN et al., 2007).

Os conceitos da agricultura de precisão têm despertado muito interesse no mundo e são considerados como a “terceira onda” na agricultura, já que a mecanização com tração animal é a primeira e a segunda onda está associada aos equipamentos motorizados (BALASTREIRE, 2000).

Muitos trabalhos científicos e bibliografias especializadas disponibilizam informações sobre a técnica da AP, que vem sendo cada vez mais utilizada no Brasil. Sua prática, no entanto, não é algo recente, pois há tempos, os agricultores têm dado tratamento localizado a suas lavouras. Conhecendo palmo a palmo cada pedaço da sua terra, estão praticando a AP, embora empírica e de baixa tecnologia (MOLIN, 2001). A proposta da AP é permitir que se faça o que pequeno agricultor sempre fez, porém, em larga escala e associando todo o conhecimento acumulado pelas ciências agrárias até hoje (MOLIN, 2002).

A crescente intensificação da produção agropecuária levou a agricultura convencional a tratar o campo de maneira uniforme, com base em valores médios, ignorando as variações espaciais e temporais dos diversos fatores envolvidos no processo de produção agrícola. O embasamento da AP está na análise das variações espaciais e temporais dos fatores de produção, tais como os teores de nutrientes, matéria orgânica e de água e, especialmente, a variabilidade do solo. A partir dessa análise, o agricultor define como aplicar, no local correto, no momento adequado, as quantidades necessárias de insumos à produção agrícola (SILVA; MORETTO; RODRIGUES, 2004).

Para Fraisse, Sudduth e Kitchen (2001), a AP tem o objetivo de mudar a forma de como o campo é gerenciado, através da aplicação de insumos em taxa variável, como fertilizantes, calcário, sementes, agrotóxicos, dentre outros. Menegatti e Molin (2003) consideram a AP como “um sistema de gerenciamento agrícola baseado na variação espacial de atributos do solo e da planta encontrada nos talhões, visando à otimização do lucro, sustentabilidade e proteção do ambiente”.

A AP apresenta perspectivas promissoras para o desenvolvimento de novas tecnologias e proposições de manejo da cultura, pois otimiza entradas e permite as reduções de custos de produção ou aumentos no rendimento, além de possíveis benefícios ambientais. Diferentes estratégias podem ser utilizadas a fim de maximizar a eficácia de insumos agrícolas aplicados em taxas variáveis. Uma estratégia baseia-se na utilização de

unidades de manejo (UM), que representam uma combinação homogênea de fatores limitantes de produtividade (MOLIN; CASTRO, 2008).

Espera-se um menor impacto ambiental com a AP (TAYLOR et al., 2003) e redução da contaminação da água e dos alimentos, a fim de proporcionar uma redução do processo erosivo (ANGELICO; SILVA, 2006).

A AP permite, pelo uso de delimitação de lavouras por coordenadas georreferenciadas, um planejamento mais racional do manejo de nutrientes, pragas, umidade do solo, plantas daninhas, além de seleção de cultivares em função de sua adaptabilidade às diferentes condições identificadas nas áreas cultivadas. A expectativa de redução de custos está, principalmente, relacionada ao fato de que os insumos agrícolas serão aplicados somente onde de fato se faz necessário e não, indiscriminadamente, em toda a extensão da área cultivada como tradicionalmente é feito (SILVA; MORETTO; RODRIGUES, 2004).

Estudos mostram que a AP pode ser aplicada nos mais diversos tipos de produção agrônômica, como é o caso da produção de peras (KONOPATZKI et al., 2009), citros (MOLIN; MASCARIN, 2007), café (MOLIN et al., 2010), eucalipto (ORTIZ et al., 2006), cana-de-açúcar (SILVA; MORAES; MOLIN, 2011) e em cultura de grãos (BAZZI et al., 2008; MOLIN et al., 2007).

3.4 Mapas temáticos

Os mapas temáticos desempenham papel de fundamental importância no processo de tomada de decisão em AP. A partir da análise de mapas temáticos, é possível verificar a distribuição espacial de atributos físicos, químicos e topográficos de uma área, assim como a resposta de produtividade de uma cultura. Para Silva; Moraes e Molin (2011), os mapas de produtividade são a chave para o gerenciamento de culturas em termos de variação espacial. Com isso, é possível identificar e delimitar quais são as regiões com maior e menor potencial produtivo.

Um mapa de produtividade representa a resposta do efeito variação espacial causada por uma combinação de fatores sobre uma cultura, que podem estar relacionados com clima, solo, relevo, entre outros, tais como a disponibilidade de nutrientes no solo, umidade do solo, competição com ervas daninhas e crescimento das culturas (STAFFORD et al., 1996).

Taylor et al. (2003) destacam que o mapa temático é a representação ideal das variações espaciais, pois mostram a magnitude da variável de interesse em todos os pontos de uma área produtiva.

Motomiya et al. (2011) trabalharam com mapas temáticos gerados com métodos da geoestatística, no qual foi possível mostrar a variabilidade espacial e o potencial de

produtividade na cultura de algodoeiro. Molin et al. (2007) geraram mapas de produtividade e de atributos físico-químicos de solo em cultura de milho e concluíram que emprego de mapas de produtividade de grãos pode contribuir para a otimização da intensidade de amostragem do solo. Os mapas de produtividade indicam as regiões que requerem maior e menor intensidade de amostras. Bazzi et al. (2008) utilizaram mapas temáticos de produtividade do milho, gerados por diferentes interpoladores, com o objetivo de avaliar a influência de distância de passadas de colhedora. Já Coelho et al. (2009) avaliaram a influência conjunta da densidade amostral e do tipo de interpolador na elaboração de mapas temáticos de produtividade da soja.

3. 4. 1 Construção de mapas temáticos

A construção de mapas temáticos abrange as seguintes etapas: coleta de dados, análise, interpretação e representação das informações. Os mapas temáticos são elaborados com a utilização de técnicas que objetivam a melhor visualização e comunicação. Distinguem-se essencialmente dos topográficos por representarem fenômenos de qualquer natureza, geograficamente distribuídos sobre a superfície terrestre (ARCHELA; THÉRY, 2008).

A partir de pontos amostrais, podem ser estimados valores em locais não conhecidos dentro de uma área. Neste caso, faz-se o uso de um método de interpolação de dados. O inverso do quadrado da distância (IQD) é um interpolador por médias simples que considera, na interpolação, os pesos inversos do quadrado da distância que separam o valor interpolado dos valores observados. Esse interpolador é definido como (Equação 1):

$$X_p = \frac{\sum_{i=1}^n \left(\frac{1}{d_i^2} \cdot X_i \right)}{\sum_{i=1}^n \left(\frac{1}{d_i^2} \right)} \quad (1)$$

em que, X_p : é a variável interpolada;

X_i : é o valor da variável i -ésima localidade vizinha;

d_i : distância euclidiana entre o i -ésimo ponto de vizinhança e o ponto amostrado.

3. 4. 2 Comparação de mapas temáticos com o índice Kappa

A comparação de mapas temáticos é utilizada para verificar semelhanças entre os mesmos. Existem índices que possibilitam verificar semelhanças quantitativas, como qualitativas entre mapas temáticos. O método padrão para avaliação da precisão temática atualmente tem sido índices derivados da matriz de confusão. A matriz de confusão fornece a base para descrever a precisão da classificação e caracterizar os erros, além de ajudar a

refinar a classificação. Várias medidas de precisão da classificação podem ser derivadas de uma matriz de confusão (FOODY, 2002).

Uma das maneiras utilizadas na determinação da exatidão de uma classificação temática é o índice Kappa (Equação 2), o qual adota uma referência para a comparação com os mapeamentos produzidos. A análise da exatidão dos mapeamentos é obtida através das matrizes de confusão e, posteriormente, é calculado o índice Kappa de concordância (CONGALTON, 1991).

$$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{n^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (2)$$

em que, K : índice Kappa de concordância;

n : número de observações (pontos amostrais);

r : número de classes da matriz de erro;

x_{ii} : número de combinações da linha i e coluna i ;

x_{i+} : total de observações da linha i ;

x_{+i} : total de observações da coluna i .

O índice Kappa tem sido utilizado na comparação de mapas temáticos. Destacam-se bons resultados obtidos na comparação de mapas gerados por diferentes interpoladores (BAZZI et al., 2009; DALPOSSO et al., 2012; SUSZEK et al., 2011).

O Kappa mede o grau de concordância além do que seria esperado tão somente pelo acaso. Esta medida de concordância tem valor máximo 1 e representa total concordância. Já os valores próximos e até abaixo de 0 indicam nenhuma concordância, ou a concordância foi exatamente a esperada pelo acaso (CORTE et al., 2007). Cabe ao pesquisador avaliar se a medida obtida é satisfatória ou não. Classificações do índice Kappa, como a de Landis e Koch (1977), auxiliam na interpretação da comparação de mapas, que classificam como: muito forte, os valores entre 0,81 a 1,00; forte, os valores entre 0,61 a 0,80; moderada, os valores entre 0,41 a 0,60; fraca, os valores entre 0,21 a 0,40; e sem concordância, quando os valores estiveram no intervalo de 0,00 a 0,20.

3.5 Correlação espacial

A dependência espacial esta relacionada à ausência de independência, que frequentemente é encontrada nos conjuntos de dados espaciais. Pode ser sintetizada na primeira Lei da Geografia de Tobler (1979): “todas as coisas são parecidas, mas coisas mais próximas se parecem mais que coisas mais distantes” (BOHÓRQUEZ; CEBALLOS, 2008). Esse conceito é conhecido como dependência ou autocorrelação positiva, que se enquadra com a afirmação de Cressie (1993), de que “a dependência espacial está presente em todas as direções e fica mais fraca à medida que aumenta a dispersão na localização dos dados”.

A autocorrelação negativa indica o contrário, que as coisas mais distantes entre si estão mais relacionadas que as coisas mais próximas (SILVA; YAMASHITA, 2007).

Os parâmetros que influenciam a agricultura são variáveis em relação ao tempo e ao espaço (JOHANN et al., 2004). A ideia de dependência espacial está associada localização relativa, porém isso não enfatiza apenas o efeito da distância física, medida em metros, mas também a distância tomada a partir das diferenças de atributos químicos e físicos do solo. As causas de dependência espaciais estão ligadas tanto nas características dos dados empregados na análise quanto na natureza dos eventos espaciais (PAIVA; KHAN, 2010). Portanto, uma variável é autocorrelacionada se uma medida feita em um ponto carrega informação sobre outra medida daquela variável registrada em outro ponto, localizado à determinada distância (CARVALHO et al., 2008).

Vários trabalhos têm mostrado que a variabilidade do solo não é puramente aleatória e apresenta correlação ou dependência espacial (MOTOMIYA et al., 2011; RACHID JUNIOR et al., 2006). A variabilidade espacial para os atributos físicos e químicos e sua relação com a estabilidade é influenciada pelo histórico de manejo das áreas de estudo (VIEIRA et al., 2011). Já a variabilidade da cultura apresenta um padrão de variabilidade semelhante quanto à distribuição na área (JOHANN et al., 2004).

É a partir da autocorrelação espacial, manifestação empírica da dependência espacial, que se percebem as explicações para determinado evento em dado local e podem ser encontradas nas regiões vizinhas. É por meio dela que se constatam, ou não, as causas existentes entre os locais e as possíveis interações entre diferentes variáveis (PAIVA; KHAN, 2010).

A dependência espacial pode ser medida por diferentes indicadores, entre eles está a estatística I de Moran. Este indicador mede a correlação espacial de uma variável de interesse; é similar ao índice de correlação de Pearson em vários aspectos (BOHÓRQUEZ; CEBALLOS, 2008; KALKHAN et al., 2007). O I de Moran é uma estatística que mede a autocorrelação espacial a partir do produto dos desvios em relação à média. É uma medida global da autocorrelação espacial, pois indica o grau de associação espacial presente no conjunto de dados (PAIVA; KHAN, 2010).

De forma geral, o I de Moran presta-se a um teste cuja hipótese nula é de independência espacial, neste caso, seu valor seria zero. Valores positivos (entre 0 e +1) indicam para correlação direta e negativos, (entre 0 e -1) para correlação inversa. Uma vez calculado, é importante estabelecer sua validade estatística e o mais comum é um teste de pseudo-significância. Neste caso, são geradas diferentes permutações dos valores de atributos associados às regiões; cada permutação produz um novo arranjo espacial, onde os valores estão redistribuídos entre as áreas. Como apenas um dos arranjos corresponde à situação observada, pode-se construir uma distribuição empírica de I de Moran. Se o valor

do I de Moran medido originalmente corresponder a um “extremo” da distribuição simulada, então trata-se de um valor com significância estatística (PAIVA; KHAN, 2010).

O I de Moran é a expressão da autocorrelação considerando apenas o primeiro vizinho. Uma indicação de autocorrelação espacial positiva revela que há uma similaridade entre os valores dos atributos estudados e da localização espacial do atributo. Ou seja, a autocorrelação espacial positiva indica que existe similaridade entre o atributo estudado e a localização espacial. Uma autocorrelação negativa, ao contrário, revela que existe dissimilaridade entre os valores do atributo estudado e da localização espacial do atributo (RABELO; PARRÉ; ALVES, 2007).

Um conceito introduzido por Wartenberg (1985) expressa a estatística de correlação cruzada entre duas variáveis, em diferentes pares de combinações Y_i e Z_i observadas em n posições, pode ser determinado por um índice conhecido como I_{YZ} (Equação 3) (BONHAM; REICH; LEADER, 1995; REICH; CZAPLEWSKI; BECHTOLD, 1994), que apresenta o grau de associação em que uma variável Y se correlaciona espacialmente com outra variável Z . Estatísticas multivariadas geralmente são usadas na previsão de parâmetros ecológicos e ambientais (KALKHAN et al., 2007). Esta estatística é usada para testar uma hipótese nula de não correlação espacial cruzada entre duas variáveis numa área de estudo. A hipótese nula de não correlação espacial cruzada é rejeitada quando o p-valor associado com o teste estatístico T for inferior a 0,05 (BONHAM; REICH; LEADER, 1995).

$$I_{YZ} = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i z_j}{W \sqrt{m_Y^2 m_Z^2}} \quad (3)$$

em que, w_{ij} : é uma matriz de associação espacial entre as posições i e j (calculado por $w_{ij} = (1/(1 + D_{ij}))$), sendo D_{ij} a distância entre os pontos i e j); y_i : é o valor da variável y transformado no ponto i ($i = 1, 2, \dots, n$), para se obter uma média zero através da fórmula $Y_i = (Y_i - \bar{Y})$, em que \bar{Y} é a média amostral da variável Y ; z_i : é o valor da variável z transformado no ponto j ($j = 1, 2, \dots, n$), para se obter uma média zero através da fórmula $Z_j = (Z_j - \bar{Z})$, em que \bar{Z} é a média amostral da variável Z ; W : é a soma de todos os graus de associação espacial, obtidos através da matriz w_{ij} , para $i \neq j$; m_Y^2 : é a variância amostral da variável y_i ; e m_Z^2 : é a variância amostral da variável z_j .

A estatística de correlação cruzada I_{YZ} é uma variação do índice I de Moran, que ao invés de calcular apenas autocorrelação associada a uma variável também calcula a correlação espacial de uma variável em função de outra.

A partir da análise da correlação e autocorrelação entre as variáveis, determinam-se quais variáveis do solo serão as mais importantes na caracterização da variabilidade presente nas áreas experimentais. A partir das variáveis selecionadas nessa análise, é possível determinar unidades de manejo diferenciado em uma área de produção agrícola pelo algoritmo de classificação, como o fuzzy C-means (BONHAM; REICH; LEADER, 1995).

3.6 Fuzzy C-means

Algoritmos de agrupamentos “fuzzy” são ferramentas matemáticas utilizadas para detectar similaridade entre membros de uma coleção de objetos (WINDHAM, 1982). Este método foi desenvolvido por Dunn (1973) e melhorado por Bezdek et al. (1981), é frequentemente usado em reconhecimento de padrões. Dunn (1973) considera que a função de um algoritmo de agrupamento é detectar subgrupos naturais dentro de um grande conjunto finito de dados X composto por vetores multidimensionais, que estão relacionados por alguma medida de distância quantitativa entre os pares de elementos de X .

A lógica fuzzy aproxima uma função por associações linguísticas de entrada e saída de dados, aplicando regras fuzzy para a teoria dos conjuntos, com o objetivo de resolver problemas na qual uma teoria mais rígida teria dificuldade de modelar. Tem a intenção de fornecer um tratamento matemático a certos termos linguísticos subjetivos, tais como “aproximadamente”, “dentre outros” e “em torno” (BARROS; BASSANEZI, 2006).

O algoritmo fuzzy C-means (FCM) é um método de agrupamento de dados não supervisionado que permite a uma parcela de dados pertencer a dois ou mais clusters. A ideia é ponderar a distância de um ponto ao centro do agrupamento por um valor de pertinência.

O algoritmo FCM classifica um conjunto de vetores de t dimensões $X = \{x_1, x_2, \dots, x_n\}$ em c clusters, onde x_j representa um vetor de valores p -dimensional de amostras $x_j = \{x_{j1}, x_{j2}, \dots, x_{jp}\} \in \mathbb{R}^p$, considerando $j = 1, \dots, n$ e $2 \leq c < n$ (CANNON; DAVE; BEZDEK, 1986). Esta baseado na minimização do índice de desempenho J_m , sendo definido como:

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^m (d_{ij})^2 \quad (4)$$

em que, u_{ji} e d_{ij} são:

$$u_{ji} = \left[\sum_{l=1}^c \left(\frac{d_{lj}}{d_{lj}} \right)^{\frac{2}{m-1}} \right]^{-1} \quad \text{onde } (m \neq 1) \quad (5)$$

$$d_{ij} = \|x_j - v_i\| = \sqrt{\sum_{l=1}^p (x_{jl} - v_{il})^2} \quad (6)$$

sendo d_{ij} a distância euclidiana, que é normalmente utilizada como métrica, entre o vetor x_j , com p características de n amostras, para o centro do cluster v_i , sendo esse definido como:

$$v_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad \text{para } i = 1, \dots, c \quad (7)$$

O algoritmo possui $V = \{v_1, v_2, \dots, v_c\}$ como um conjunto de vetores que representa os c centros das categorias. U representa uma matriz de graus de pertinência fuzzy, em que um elemento u_{ij} é o grau de pertinência da j -ésima amostra x_j com o i -ésimo centro de cluster v_i , ou seja, indica em que grau o ponto amostral x_j pertence ao cluster $v_i = \{v_{1i}, v_{2i}, \dots, v_{ti}\}$ sendo $i = \{1, 2, \dots, c\}$, cujo resultado é a matriz $U = (u_{ij})_{n \times c}$. A matriz U deve seguir as seguintes condições:

$$\sum_{i=1}^c u_{ij} = 1, \forall j \quad (8)$$

$$0 < \sum_{j=1}^n u_{ij} < n, \forall i \quad (9)$$

Ao se seguir a equação 8, garante-se a condição de que o somatório dos graus de inclusão de uma amostra em todas as categorias deve ser igual a 1 e a equação 9 garante que nenhuma categoria pode estar vazia ou conter todos os elementos (WINDHAM, 1982).

O expoente m na equação 4 é chamado de índice de fuzzificação e é usado para definir a distância permitida entre os pontos e o centro que está sendo calculado. Quanto maior o valor de m , mais elementos do conjunto são considerados como pertencentes a uma pseudopartição. Quando m tende a 1, a matriz U tende a ser rígida, ou seja, um elemento poderá pertencer somente a uma categoria com grau 1. No entanto, a literatura sugere que m seja igual a 1,25, mantendo-se o proposto por Cannon, Dave e Bezdek (1986) $1 < m < \infty$.

Esse parâmetro é escolhido de acordo com o problema considerado. As etapas básicas do algoritmo FCM podem ser resumidas da seguinte forma (BEZDEK et al., 1981; CANNON; DAVE; BEZDEK, 1986):

- Definir o número de clusters c , considerando $2 \leq c < n$, em que n é o número de amostras;
- Definir o valor do índice de fuzzificação m ;
- Definir o valor do critério de parada ε ($\varepsilon > 0$);
- Inicializar a matriz de pertinências fuzzy $U = [u_{ij}]$, $U^{(0)}$;
- Calcular o índice de desempenho J_m (equação 4). Repetir até que o erro calculado seja menor que ε :
 - Calcular o vetor V dos centros de cluster v_i , considerando $i = 1, 2, \dots, c$ (Equação 7);

- Calcular a distância (euclidiana) d_{ij} da amostra x_j ao centro do cluster v_i (Equação 6);
- Atualizar a matriz partição difusa U , pelo cálculo de todos os u_{ji} com base na (Equação 5), com as seguintes considerações:
 - Se $d_{ij} > 0$ então: equação 5;
 - Senão:
 - Se $d_{ij} = 0$ então: $u_{ij} = 1$;
 - Senão: $u_{ij} = 0$.

O critério de parada do algoritmo deve estar relacionado ao momento em que se chega em um estado no qual as posições dos centros das categorias calculadas em um dado instante praticamente não diferem das posições em um instante anterior.

Algoritmos FCM são utilizados em diferentes áreas para realizar a classificação de dados, inclusive na agricultura. A classificação algorítmica não supervisionada FCM pode ser encontrada em trabalhos que envolvem a AP, como no delineamento de unidades de manejo utilizado em dados de condutividade elétrica (FRIDGEN; KITCHEN; SUDDUTH, 2000; MORARI; CASTRIGNANÒ; PAGLIARIN, 2009). Vitharana et al. (2008) utilizaram o método FCM para delinear unidades de manejo, baseados em dados de solo e topografia.

Sistemas de informação geográfica (SIG) possuem algoritmos de agrupamento que permitem a divisão de um conjunto de dados em clusters. No caso de delineamento de unidades de manejo por este método, a escolha do valor das classes não é configurável, sendo por isto considerado uma vantagem em relação aos delineamentos empíricos (FRIDGEN et al., 2004).

3. 6. 1 Validação de clusters

O algoritmo fuzzy C-means produz centros de cluster e graus de adesão para diferentes números de clusters, $c \in \{2, 3, \dots\}$. Medidas de validação de clusters têm sido propostas para ajudar a decidir se os agrupamentos sugeridos pelo algoritmo não supervisionado fornecem uma partição significativa do conjunto de dados.

O índice de desempenho fuzzy (FPI: *Fuzziness Performance Index*) é um índice que mede o grau de separação (isto é, confusão) entre os c -clusters fuzzy de um conjunto de dados X . FPI pode variar de 0 a 1. Valores que se aproximam de zero (0) indicam classes distintas e apresentam pequeno grau de compartilhamento dos membros (dados) entre elas, enquanto os valores próximos de um (1) indicam não haver classes distintas e apresentam elevado grau de compartilhamento dos membros entre as classes (FRIDGEN et al., 2004). O FPI é definido como (MCBRATNEY; MOORE, 1985):

$$FPI = 1 - \frac{c}{(c-1)} \left[1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad (10)$$

em que, c : número de clusters;

n : número de observações;

u_{ij} : é o elemento ij da matriz de pertinência fuzzy U .

Outro índice é a partição da entropia modificada (MPE: *Modified Partition Entropy*), que estima a quantidade de desorganização criada por um número específico de clusters. Seus valores podem variar entre 0 e 1. Quando o valor do MPE se aproxima de um (1), predomina a desorganização, e quando os valores se aproximam de zero (0) indicam melhor organização (BOYDELL; MCBRATNEY, 2002). O MPE é calculado a partir de (MCBRATNEY; MOORE, 1985):

$$MPE = \frac{-\sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) / n}{\log c} \quad (11)$$

em que, c : número de clusters;

n : número de observações;

u_{ij} : é o elemento ij da matriz de pertinência fuzzy U .

O melhor número de agrupamentos (*clusters*) de um conjunto de dados é estabelecido com base no valor mínimo destas duas medidas (BOYDELL; MCBRATNEY, 2002). Em trabalhos relacionados com a AP é possível encontrar a utilização dos índices FPI e MPE na validação de agrupamentos formados pelo algoritmo fuzzy C-means (ARNO et al., 2011; GUASTAFERRO et al., 2010; MOLIN; CASTRO, 2008; MORARI; CASTRIGNANÒ; PAGLIARIN, 2009; XIANG et al., 2007).

3.7 Unidades de Manejo

A variabilidade espacial e temporal dos atributos do solo e as condições meteorológicas podem afetar o crescimento, a qualidade e a produtividade final da cultura (GUASTAFERRO et al., 2010). Levando-se em conta as práticas da AP, que procuram diminuir a influência dos fatores que interferem na produtividade e estão baseadas na aplicação de insumos em taxa variável, é possível delimitar unidades de manejo diferenciado no campo para facilitar a aplicação das técnicas da AP, pois, para Rodrigues Junior et al. (2011), é possível empregar os mesmos sistemas utilizados na agricultura convencional no manejo das culturas.

O conceito de unidade de manejo está relacionado com a divisão de uma área produtiva com grande variabilidade espacial em regiões menores dentro da mesma, na qual se obtém a redução da variabilidade espacial em cada sub-região (ROUDIER et al., 2011). Portanto, a definição de unidades de manejo surge como alternativa para se viabilizar

economicamente a utilização da AP. Funciona como unidade de operação para aplicação localizada de insumos e como indicador para amostragem do solo e da cultura (RODRIGUES; ZIMBACK, 2002).

No caso de amostragem de solo, para se identificar a variabilidade espacial de atributos físico-químicos que interferem na produtividade da cultura, evita-se, com unidades de manejo, a utilização de uma grade amostral densa como necessária em AP, por conseguinte, há uma diminuição no custo das análises laboratoriais.

A determinação de unidades de manejo visa simplificar a representação da variabilidade espacial dentro do campo (ROUDIER et al., 2011). O gerenciamento de pequenas regiões uniformes em termos de atributos relacionados com a fertilidade do solo, os quais são de grande importância para o desenvolvimento das culturas, é considerado por Molin e Castro (2008) como uma das etapas mais desafiadoras da AP, que pode ser atingido com a divisão da área em unidades de manejo.

A identificação dessas sub-regiões pode ser feita com informações da área do campo, consideradas homogêneas em algum fator que pode ser medido quantitativamente e que, de alguma forma, interferem no desenvolvimento e na produtividade da planta, como: topografia, produtividade, atributos físico-químicos do solo, nutrientes ou indicadores compostos (FRIDGEN et al., 2004; MOLIN, 2002). A determinação dessas sub-regiões é um tanto difícil, devido a uma complexa combinação dos fatores climáticos, bióticos e de solo, os quais afetam a produtividade. Esses fatores interagem de forma dinâmica, portanto, complicam ainda mais as decisões de como gerenciar o campo em unidades (FRIDGEN et al., 2004). Surge a necessidade de avaliar quais fatores influenciam a produtividade da cultura e considerá-los no processo de divisão da área em unidades de manejo.

Vários pesquisadores utilizaram as unidades de manejo, com sucesso, mesmo que tenham seguido metodologias diferentes. De acordo com Xiang et al. (2007), basicamente, as metodologias para delimitação de unidades de manejo podem ser classificadas em métodos empíricos e técnicas de agrupamento de dados.

Destacam-se os trabalhos desenvolvidos utilizando produtividade (ANUAR et al., 2008; BLACKMORE, 2000; MILANI et al., 2006; MOLIN, 2002; RODRIGUES; ZIMBACK, 2002; STAFFORD et al., 1996; SUSZEK et al., 2011; XIANG et al., 2007), população de invasoras (BAZZI et al., 2009), videografia aérea (ARAÚJO; VETTORAZZI; MOLIN, 2005), e a combinação de dados topográficos e de solo (FRAISSE; SUDDUTH; KITCHEN, 2001).

A definição por métodos empíricos, considerados mais simples, geralmente usa a frequência de distribuição de mapas de produtividade (normalmente relativa) e conhecimento especializado para dividir o talhão em unidades de manejo (BLACKMORE, 2000), pois Molin (2002) considera o mapa de produtividade como a informação mais completa para se visualizar a variabilidade espacial da lavoura.

Quando utilizados mapas de produtividade de anos consecutivos, existe a necessidade de que sejam removidos os impactos temporais (chuva acentuada em certos anos e estiagem em outros), os quais, de alguma maneira, podem ter influenciado a produtividade da cultura. Neste sentido, trabalhos foram desenvolvidos com o objetivo de neutralizar essa influência, através de sua normalização, dividindo-se a produtividade em cada posição do talhão pela produtividade média da safra correspondente (BLACKMORE, 2000; MOLIN, 2002; XIANG et al., 2007). Outra forma é pela transformação da produtividade em escore padrão (MILANI et al., 2006; RODRIGUES; ZIMBACK, 2002).

Para Fraisse, Sudduth e Kitchen (2001), a definição de unidades de manejo pelo método empírico está sujeita a decisões subjetivas. Entretanto, outras técnicas, como a lógica nebulosa fuzzy C-means, podem realizar a divisão da área automaticamente a fim de que sejam formados agrupamentos (*clusters*), sem a subjetividade da divisão em classes escolhidas por uma pessoa (FRIDGEN et al., 2004). Esta abordagem para geração de unidades de manejo é considerada muito promissora por Yan et al. (2007), pois está baseada na análise de clusters formados por diferentes fontes de dados, possibilitando o uso de um conjunto de fatores proeminentes do desenvolvimento das culturas. Com base nisso, Fraisse, Sudduth e Kitchen (2001) complementam que o gerenciamento da área, baseado na utilização de fatores limitantes de produtividade, proporciona uma aplicação de insumos mais precisa.

Trabalhos foram desenvolvidos utilizando o método de análise de agrupamento a partir do algoritmo fuzzy C-means, a partir dos atributos do solo (VITHARANA et al., 2008), atributos de solo mais a condutividade elétrica do solo (MOLIN; CASTRO, 2008; MORARI; CASTRIGNANÒ; PAGLIARIN, 2009), além da adição de imagens digitais com índice de vegetação (YAN et al., 2007). Rodrigues Junior et al., (2011) se basearam em dados de clorofila e concentração foliar de plantas de café. Também existem trabalhos que fazem uso da lógica fuzzy C-means com dados de diferentes anos de produtividade (ARNO et al., 2011; GUASTAFERRO et al., 2010; PING; DOBERMANN, 2003; XIANG et al., 2007).

Depois de geradas as unidades de manejo, é importante verificar a sua validade em questões práticas. Xiang et al. (2007) utilizaram o índice de redução de variância (VR) para avaliar a diminuição da variância sobre a produtividade do trigo em diferentes delineamentos de unidades de manejo, assim como Ping e Dobermann (2003) sobre dados de produtividade de milho e soja. Análise de variância (ARNO et al., 2011) e interpretação de boxplots também são técnicas utilizadas para esta finalidade.

4 MATERIAL E MÉTODOS

4.1 Localização da área experimental

O experimento foi realizado numa área de 19,6 ha, iniciado em abril de 2009 e conduzido até janeiro de 2011. A área experimental está localizada no município de Cascavel (Figura 1), situada no Oeste do Paraná, cujas coordenadas geográficas são 24°57'19" de latitude Sul e 53°33'59" de longitude Oeste, a uma altitude média de 706 metros. O solo da área é um Latossolo Vermelho Distroférrico típico com textura argilosa (EMBRAPA, 2006). A precipitação média anual no município é de 1970 mm e a temperatura média anual de 19 °C.




Figura 1 Localização da área experimental.
Fonte: adaptado de Google Earth (2009).

A área experimental foi manejada sob sistema de plantio direto há 10 anos com sucessão das culturas de soja, milho e aveia. As correções periódicas de calcário e adubação com nitrogênio, fósforo e potássio foram baseadas nas análises químicas do solo e recomendações técnicas. Anteriormente à instalação do experimento, a área havia sido cultivada com aveia.

Fez-se o georreferenciamento da área a partir de um aparelho receptor GPS Trimble Geo Explorer XT 2005, com correção pós-processada.

4.2 Coleta dos dados

O software *Trimble GPS Pathfinder Office*, versão 4.0, permitiu que fossem geradas grades amostrais (Figura 2) de espaçamento irregular com distâncias de 20, 40 e 80 metros entre os pontos amostrais, os quais foram demarcados com base no direcionamento das curvas de nível da área.

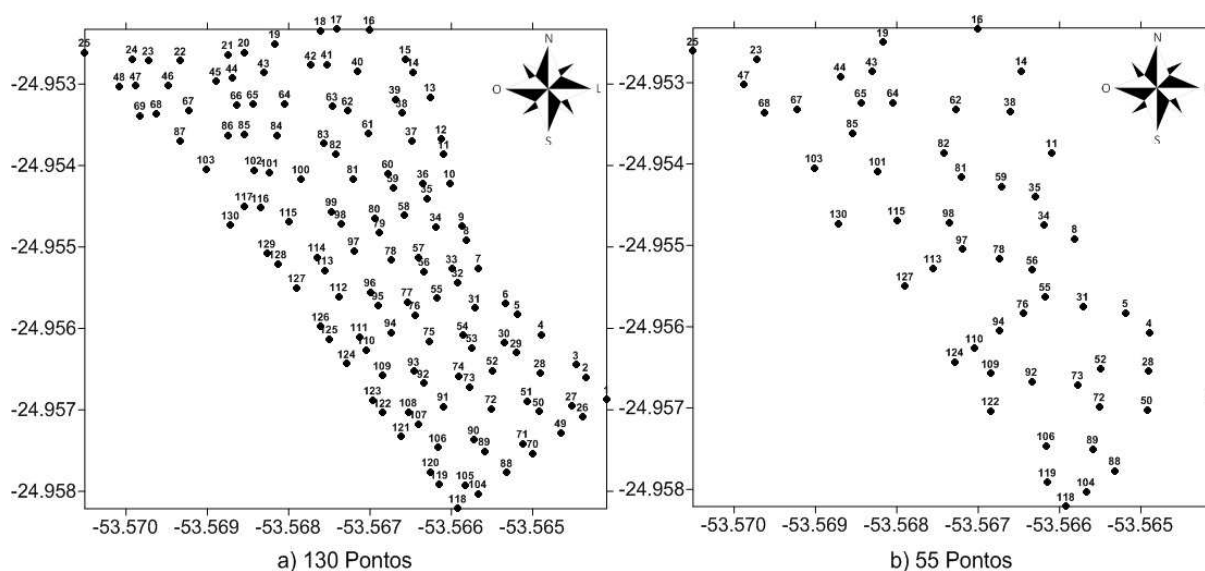


Figura 2 Densidade amostral de 130 e 55 pontos sobre a área experimental.

Para a geração das unidades de manejo com base nos atributos físico-químicos do solo e topográficos que tenham correlação espacial com a produtividade da soja na área de estudo, foram feitos levantamentos de dados por meio da análise de solo e coleta manual de produtividade.

As amostras de solo em 55 pontos distintos na área (Figura 2) foram coletadas para os dados de resistência do solo à penetração (RSP) e dos atributos químicos do solo. A coleta de solo e a medição da resistência do solo à penetração foram realizadas em outubro de 2010. A RSP foi medida com um penetrômetro Falker SoloTrack PLG1020, nas camadas de 0 a 0,20 m de profundidade. As amostras de solo para análise dos atributos químicos do solo foram coletadas na camada de 0 a 0,20 m de profundidade, com trado holandês obedecendo a um arranjo sistemático com 4 subamostras num raio de 3 metros em torno do ponto georreferenciado.

As amostras de textura do solo foram coletadas em 45 pontos, de onde uma amostra composta foi retirada por ponto georreferenciado, na camada de 0 a 0,20 m de profundidade do solo, no ano de 2009.

As análises de solo, para levantamento dos dados de atributos químicos e de textura do solo, foram realizadas no laboratório da Cooperativa Central de Pesquisa Agrícola (COODETEC), no município de Cascavel - PR. As análises foram realizadas para a obtenção dos valores quantitativos de potencial de hidrogênio (pH), fósforo (P), potássio (K),

cobre (Cu), zinco (Zn), ferro (Fe), manganês (Mn), cálcio (Ca), magnésio (Mg), carbono (C), alumínio (Al) e teores de areia, argila e silte.

Os dados de produtividade foram obtidos a partir da cultura da soja da variedade Nidera NA 4990 RG, semeada no dia 09 de outubro de 2010, em sistema de plantio direto, com espaçamento de 0,45 m entre as linhas. Coletaram-se amostras em 130 pontos (Figura 2) de forma manual no espaçamento de 1 m x 0,90 m para cada amostra (Figura 3), que resulta na coleta de plantas em duas linhas de semeadura. Após coletada a amostra, as plantas foram acondicionadas em sacos (tipo ráfia), trilhadas, para que fossem medidos a massa total de grãos da amostra e o teor de água dos grãos, visando corrigi-los para um nível de teor de água de 12%.




Figura 3 Espaçamento utilizado na coleta de amostras da produtividade de soja na área experimental.

4.3 Análise exploratória dos dados

Na análise exploratória dos dados, foram calculadas as medidas de posição (média e mediana), medidas de dispersão (variância, desvio padrão e coeficiente de variação (CV)) e medidas de forma da distribuição (coeficiente de assimetria e coeficiente de curtose), visando identificar e avaliar se os dados possuem homogeneidade e normalidade.

O CV foi classificado conforme proposto por Pimentel Gomes e Garcia (2002): baixo, quando $CV \leq 10\%$; médio, quando $10\% < CV \leq 20\%$; alto, quando $20\% < CV \leq 30\%$; e muito alto, quando $CV > 30\%$.

A normalidade dos dados foi verificada pelos testes de Anderson-Darling e Kolmogorov-Smirnov. Os dados que em, pelo menos, um dos testes apresentou normalidade dos dados com 5% de significância, foram considerados com distribuição de probabilidade normal. Os pontos discrepantes foram verificados por meio de boxplots para analisar se possivelmente foram valores com erro de amostragem.

Os dados da análise exploratória e a normalidade dos dados foram calculados com auxílio do software MINITAB® 16 (MINITAB INC, 2010).

4.4 Análise de autocorrelação e correlação espacial entre variáveis

Analisou-se a correlação espacial entre as variáveis respostas sobre os conjuntos de dados amostrais dos atributos químicos e físicos do solo, produtividade e da topografia. As variáveis respostas foram avaliadas em diferentes pares de combinações Y_i e Z_i observadas em n posições através da estatística de correlação espacial cruzada I_{YZ} (Equação 3).

A hipótese nula de não autocorrelação espacial foi rejeitada quando o p-valor associado com a estatística de teste foi inferior a 0,05.

A matriz de correlação espacial foi gerada para as variáveis respostas analisadas, em cuja diagonal principal encontram-se os valores de autocorrelação de cada variável e fora da diagonal principal, encontram-se os valores de correlação cruzada entre as variáveis. As informações apresentadas na matriz são os valores calculados da estatística de correlação espacial cruzada I_{YZ} e a significância do teste para cada combinação de variáveis, considerando os níveis de 1% e 5% de significância.

As estimativas de autocorrelação espacial e estatística de correlação cruzada (I_{yz}) para as variáveis (atributos físicos e químicos do solo, topográfico e produtividade) foram calculadas com auxílio do módulo Spatial para o software R.

Utilizou-se um teste de pseudo-significância, no software R, fornecido pelo módulo Spatial, para garantir a validade estatística do resultado de autocorrelação ou correlação cruzada entre as variáveis, que realiza diferentes permutações dos valores de atributos associados às regiões. Esse teste foi realizado com 999 permutações diferentes sobre os conjuntos de dados.

A seleção das variáveis utilizadas no processo de delineamento das unidades de manejo ocorreu a partir da análise da matriz correlação espacial. Inicialmente, selecionaram-se as variáveis que possuem autocorrelação espacial, na diagonal principal da matriz, e dentre essas variáveis; no segundo momento, selecionaram-se aquelas que possuem correlação espacial cruzada significativa com os dados de produtividade da cultura em estudo. Com as variáveis selecionadas, fizeram-se diferentes combinações possíveis entre as variáveis, em que cada combinação foi denominada como um delineamento de unidade de manejo.

4.5 Interpolação dos dados

A partir dos dados amostrais das variáveis selecionadas, foram estimados os valores para as regiões não amostradas da área de estudo. Utilizou-se o método de interpolação inverso do quadrado da distância (Equação 1). Etapa importante para que o algoritmo fuzzy C-means classifique os dados de toda a área. Os dados foram interpolados através do software Golden Surfer 10.

4.6 Normalização dos dados

Faz-se necessário normalizar os dados para que não haja peso maior de uma variável sobre o processo de agrupamento dos dados no delineamento das unidades de manejo, devido às variáveis em estudo possuírem diferentes medidas quantitativas. Os dados das variáveis selecionadas foram normalizados conforme (Equação 12):

$$P_{iNorm} = \frac{P_i - Mediana}{Amplitude} \quad (12)$$

em que: P_i é o pixel i a ser normalizado e P_{iNorm} é o pixel normalizado (MIELKE; BERRY, 2007).

O processo de normalização dos dados foi realizado com auxílio do software Microsoft Office Excel® 2010 (MICROSOFT CORPORATION, 2010).

4.7 Delimitação das unidades de manejo

Nesse passo, realizou-se a divisão da área em sub-regiões usando o algoritmo fuzzy C-means para fazer agrupamento dos dados das variáveis selecionadas a partir da matriz de correlação espacial, em que cada sub-região foi considerada como uma classe de unidade de manejo.

Os dados das variáveis utilizadas em cada delineamento de unidade de manejo foram colocados em um arquivo de texto e padronizados em colunas, seguindo-se da primeira coluna com o número de identificação dos pontos e as demais colunas com os valores de cada variável (X, Y, Z, ...). Com os dados padronizados em arquivos de texto, utilizou-se o software FuzME (MINASNY; MCBRATNEY, 2002) para realizar o processo de agrupamento dos dados de cada delineamento de unidades de manejo.

No FuzME, o número mínimo e o máximo de classes de unidades de manejo a ser estabelecido foram configurados como parâmetros; escolha essa necessária ao software FuzME para dar início ao processo de agrupamento. Tal escolha foi realizada de forma arbitrária, em que se escolheu 2 para quantidade mínima e 5 para quantidade máxima de classes, assumindo-se que a quantidade estipulada de unidades de manejo pudesse ter aplicabilidade prática na administração das áreas. Fez-se necessário definir o número máximo de iterações, o expoente fuzzy, o critério de encerramento da análise e o tipo de critério de distância a ser utilizado entre as observações e o centroide de cada classe. Neste caso, a análise foi baseada nas distâncias euclidianas² entre os centroides e as observações, considerando um expoente fuzzy de 1,30, número máximo de 300 interações

² Corresponde à distância geométrica entre dois pontos no plano multidimensional.

e critério de parada ou erro de 0,0001. Os valores utilizados estão baseados nas configurações padrões propostas pelo próprio FuzME. Molin e Castro (2008) utilizaram o software FuzME para gerar unidades de manejo com base nos critérios de distância euclidiana e expoente fuzzy de 1,20.

A informação resultante dessa análise, fornecida pelo software FuzME, são os valores percentuais da função de participação de cada ponto do mapa (pixel) nas C classes de unidades de manejo definidas. Os dados de classificação em unidades de manejo fornecidos pelo FuzME foram importados para o software Microsoft Office Excel® 2010 para adequação, colocando-se as coordenadas geográficas. E para a visualização dos mapas de unidades de manejo, utilizou-se o software Golden Surfer 10.

4.8 Avaliação das unidades de manejo

As unidades de manejo foram avaliadas por cinco métodos diferentes: índice de eficiência relativa (ER), análise de variância (ANOVA), boxplots, índices FPI e MPE, assim como o índice Kappa. A finalidade foi identificar se cada uma das formas de divisão em unidades de manejo apresenta potencial de produtividade diferente entre as classes geradas, para assim encontrar a melhor forma de divisão da área.

A eficiência relativa de uma UM mostra se a UM delimitada é mais eficiente do que o conjunto, calculado, com auxílio do software Microsoft Office Excel® 2010, de acordo com a (Equação 13):

$$ER = \frac{Var_{AT}}{Var_{ZM}} \quad (13)$$

considerando as sub-equações,

$$Var_{AT} = \frac{s^2_{AT}}{n} \quad (14)$$

$$Var_{ZM} = W_i^2 * \frac{s_i^2}{n_i} \quad (15)$$

em que, s^2_{AT} : é a variância dos dados amostrais na área total;

n : é o número de observações (total de pontos);

s^2_i : é a variância dos dados amostrais da zona de manejo i ;

n_i : é o número de observações da zona de manejo i ; e

W_i : é a proporção do campo na unidade de manejo i .

A partir do software SISVAR 5.1 (FERREIRA, 2008), realizaram-se as análises de variância sobre a produtividade da soja entre as classes de UM. Em todas as combinações de unidades geradas, considerou-se a produtividade como variável independente. O objetivo foi verificar se existem diferenças médias significativas de produtividade da soja entre as

classes de unidades de manejo, para cada uma das combinações propostas. Maiores diferenças de médias entre as classes são mais esperadas para uma maior validade do delineamento em unidades de manejo. Para a realização das comparações de média entre as unidades de manejo, foi utilizado o teste HSD (*Honest Significant Difference*) de Tukey, usando como parâmetro um nível de 5% de significância.

Boxplots da produtividade da soja foram criados para cada UM, com o objetivo de ajudar a determinar se as tendências encontradas nos atributos físico-químicos do solo, que foram usados no delineamento das unidades de manejo, correspondem ao potencial de produtividade das unidades de manejo. Utilizou-se o software estatístico MINITAB® para a geração dos boxplots.

Os índices FPI e MPE foram utilizados a fim de se verificar o grau de separação e de desorganização entre as classes de UM em cada um dos delineamentos. Tais índices são fornecidos pelo próprio programa FuzME. O número de classes de agrupamentos (unidades de manejo) com maior diferenciação entre elas foi considerado como aquele no qual esses dois índices atingiram aproximadamente o valor mínimo em cada delineamento (FRIDGEN; KITCHEN; SUDDUTH, 2000).

O índice Kappa foi utilizado para avaliar, pixel-a-pixel, a concordância espacial entre os mapas de unidades de manejo mais eficientes. O Kappa foi calculado através das matrizes de confusão, com auxílio do software Microsoft Office Excel® 2010. Considerou-se o grau de classificação para o índice Kappa, conforme Landis e Koch (1977).

5 RESULTADOS E DISCUSSÃO

5.1 Análise exploratória dos dados

Os atributos C, pH, argila e altitude (Tabela 1) apresentaram variabilidades (PIMENTEL GOMES; GARCIA, 2002) consideradas baixas, enquanto a produtividade e os atributos Fe, Mn, Ca, silte, resistência do solo à penetração nas camadas 0-0,20 m (RSP_0_20) e 0,10-0,20 m (RSP_10_20) tiveram variabilidades médias. Os dados amostrais dos atributos H+Al e Mg foram considerados com variabilidades altas. Por fim, os atributos Cu, Zn, P, Al, K, areia e resistência do solo à penetração na camada 0-0,10 m (RSP_0_10) tiveram variabilidades consideradas muito altas. Os dados de produtividade da soja apresentaram-se com variabilidade média.

Tabela 1 Estatística descritiva dos dados

Atributo	N	Mínimo	Média	Mediana	Máximo	Desvio Padrão	CV (%)	Assimetria	Curtose	Normal*
Produtividade (t ha ⁻¹)	130	2,09	3,29	3,29	4,64	0,52	16 (m)	0,14 (a)	-0,20 (A)	Sim
Teor de Cu (mg dm ⁻³)	55	1,00	2,24	2,11	4,21	0,93	41 (ma)	0,34 (a)	-0,97 (B)	Sim
Teor de Zn (mg dm ⁻³)	55	1,00	1,61	1,32	4,04	0,79	49 (ma)	1,32 (b)	0,98 (A)	Não
Teor de Fe (mg dm ⁻³)	55	14,00	18,40	18,00	30,00	2,85	16 (m)	1,29 (b)	3,81 (C)	Sim
Teor de Mn (mg dm ⁻³)	55	37,00	49,65	49,00	68,00	6,69	13 (m)	0,69 (b)	0,83 (A)	Sim
Teor de P (mg dm ⁻³)	55	6,40	15,12	13,80	39,60	7,05	47 (ma)	1,52 (b)	2,62 (C)	Não
Teor de C (g dm ⁻³)	55	28,05	33,08	33,12	37,79	2,39	7 (b)	0,18 (a)	-0,58 (A)	Sim
pH	55	4,50	5,24	5,20	6,00	0,35	7 (b)	0,15 (a)	-0,50 (A)	Sim
H+Al (cmolc dm ⁻³)	55	3,97	6,23	6,21	9,70	1,32	21 (a)	0,52 (a)	-0,23 (A)	Sim
Teor de Ca (cmolc dm ⁻³)	55	3,79	6,74	6,75	9,90	1,34	20 (m)	0,06 (a)	-0,36 (A)	Sim
Teor de Mg (cmolc dm ⁻³)	55	1,44	2,22	2,12	3,82	0,54	24 (a)	1,26 (b)	1,99 (C)	Sim
Teor de Al (cmolc dm ⁻³)	55	0,00	0,04	0,00	0,61	0,11	260 (ma)	3,15 (b)	11,40 (C)	Sim
Teor de K (cmolc dm ⁻³)	55	0,09	0,28	0,28	0,60	0,11	38 (ma)	0,56 (a)	0,43 (A)	Sim
RSP_0_10 (mPa)	55	0,31	0,62	0,63	1,09	0,20	31 (ma)	0,27 (a)	-0,71 (A)	Sim
RSP_0_20 (mPa)	55	0,89	1,28	1,29	1,65	0,18	14 (m)	-0,03 (a)	-0,56 (A)	Sim
RSP_10_20 (mPa)	55	1,43	1,94	1,96	2,40	0,20	11 (m)	-0,49 (a)	0,42 (A)	Sim
Altitude (m)	55	701,00	706,29	702,00	712,00	3,33	0,5 (b)	0,19 (a)	-1,21 (B)	Sim
Teor de Argila (%)	45	60,00	70,00	72,00	79,00	5,00	7 (b)	-0,88 (c)	0,20 (A)	Não
Teor de Areia (%)	45	6,00	10,00	9,00	19,00	4,00	39 (ma)	1,21 (b)	1,22 (A)	Não
Teor de Silte (%)	45	15,00	20,00	19,00	25,00	2,00	11 (m)	0,64 (a)	-0,24 (A)	Sim

N – Número de elementos amostrais; Simetria: Simétrica (a); Assimétrica positiva (b); Assimétrica negativa (c); Curtose: Mesocúrtica (A); Platicúrtica (B); Leptocúrtica (C); * Não Normal a 5% de probabilidade; Coeficiente de Variação (CV): baixo (b), médio (m), alto (a), muito alto (ma); RSP_0_10: resistência do solo à penetração na camada 0 a 0,10 m; RSP_0_20: resistência do solo à penetração na camada 0 a 0,20 m; RSP_10_20: resistência do solo à penetração na camada 0,10 a 0,20 m.

O aspecto textural do solo (Tabela 1) apresenta-se como argiloso (mínimo de 60% de argila). Todavia, com relação à compactação do solo, verifica-se que a área apresenta-se com compactação mais acentuada na camada de 0,10 a 0,20 m, onde há maior resistência do solo à penetração (em média 1,94 mPa). Os valores médios de resistência do solo à penetração ficaram muito próximos da mediana em cada camada avaliada. A menor

compactação do solo na área foi encontrada na camada de 0 a 0,10 m (0,31 mPa), já a maior compactação apresentada foi na camada 0,10 a 0,20 m (2,40 mPa).

Os atributos de produtividade, Cu, Fe, Mn, C, pH, H+Al, Ca, Mg, Al, K, RSP_0_10, RSP_0_20, RSP_10_20, altitude e silte (Tabela 1) apresentaram normalidade por pelo menos um dos testes realizados. Já os atributos Zn, P, argila e areia não apresentaram normalidade. Como esperado, os valores das médias e medianas foram próximos dos valores das variáveis que apresentaram normalidade.

Os parâmetros apresentaram distribuição simétrica em doze casos (produtividade, Cu, C, pH, H+Al, Ca, K, RSP_0_10, RSP_0_20, RSP_10_20, altitude e silte), distribuição assimétrica positiva em sete casos (Zn, Fe, Mn, P, Mg, Al e areia) e um caso com distribuição assimétrica negativa (argila). Em quatorze casos, encontrou-se distribuição mesocúrtica (produtividade, Zn, Mn, C, pH, H+Al, Ca, K, RSP_0_10, RSP_0_20, RSP_10_20, argila, areia e silte); dois casos apresentaram distribuição platicúrtica (Cu e altitude) e quatro casos tiveram distribuição leptocúrtica (Fe, P, Mg e Al).

No boxplot para os dados de produtividade da soja (Figura 4 (q)) pode-se observar um ponto discrepante, para o valor de 2,09 t ha⁻¹. Além da produtividade, o boxplot das variáveis Zn (Figura 4 (b)), Fe (Figura 4 (c)), Mn (Figura 4 (d)), P (Figura 4 (e)), Mg (Figura 4 (i)), Al (Figura 4 (j)), K (Figura 4 (k)), H+Al (Figura 4 (l)) e Teor de Areia (Figura 4 (s)) apresentou um ou mais pontos discrepantes. O Al foi o atributo que apresentou maior quantidade de pontos discrepantes e isso ocorreu porque, na maioria das amostras analisadas, não se encontrou o elemento, sendo encontrado em apenas nove das 55 amostras. Os pontos discrepantes não foram retirados por não se poder concluir que foram erros amostrais.

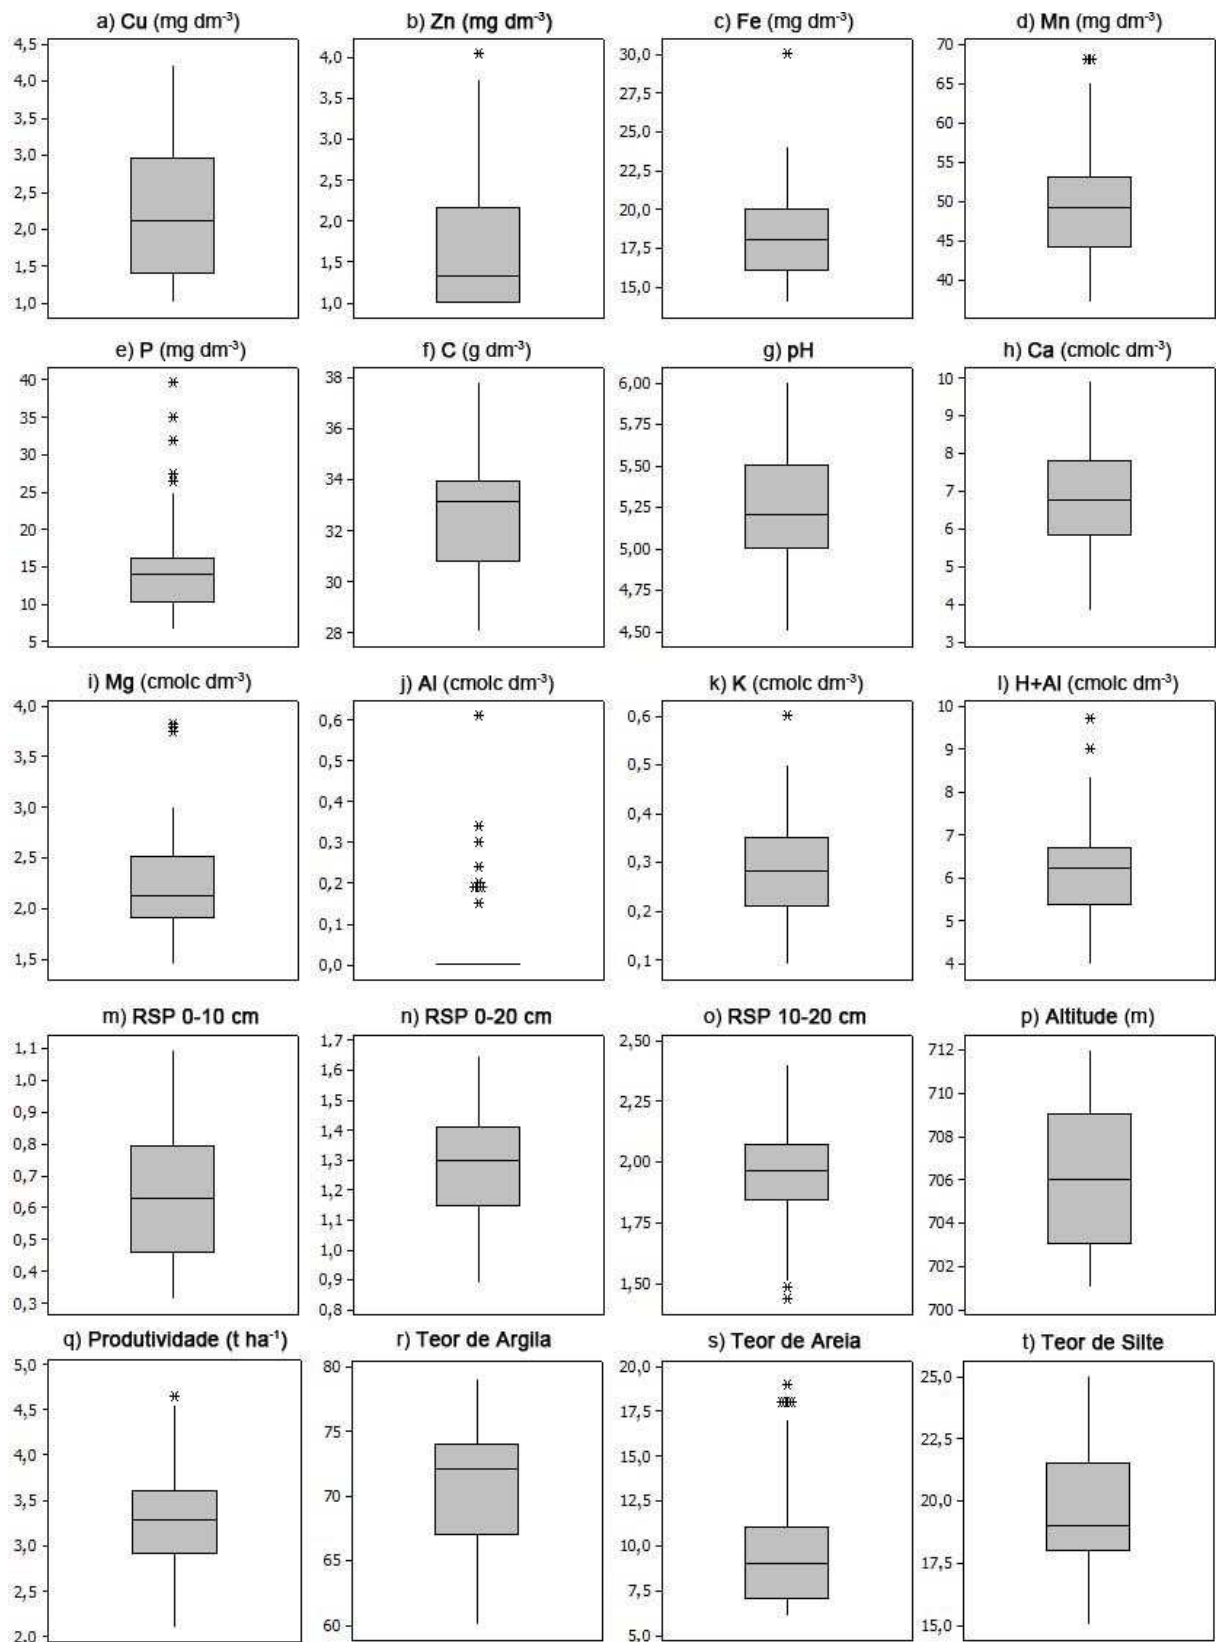


Figura 4 Boxplot das variáveis analisadas.

5.2 Análise de correlação espacial entre variáveis

De acordo com as estimativas de correlação espacial cruzada (I_{yz} , Tabela 2), verifica-se nos elementos da diagonal principal da matriz que as variáveis C, Cu, argila, areia, silte e altitude apresentaram autocorrelação espacial com 1% de significância. Já a variável Mn apresentou autocorrelação espacial com 5% de significância. As variáveis Cu, silte e altitude apresentaram correlação espacial positiva com a produtividade. Entretanto, as variáveis K e argila apresentaram correlação espacial negativa com a produtividade, todas com o nível de 5% de significância (Tabela 2). Das variáveis que possuem autocorrelação espacial significativa, apenas Cu, argila, silte e altitude possuem correlação espacial significativa com a produtividade.

Tabela 2 Matriz de correlação espacial das variáveis analisadas na área de estudo

Prod.	0,010738 NS																				
P	0,001112 NS	0,007189 NS																			
Ca	-0,013443 NS	0,005593 NS	-0,001804 NS																		
C	0,009269 NS	-0,023456 NS	0,021975 NS	0,052728 **																	
Cu	0,092844 **	-0,045115 **	0,038824 *	0,138677 **	0,323292 **																
Fe	-0,023504 NS	0,014713 NS	0,014031 NS	-0,017799 NS	-0,117625 **	0,000347 NS															
H+AL	0,015167 NS	-0,017013 NS	0,013254 NS	-0,005938 NS	-0,012716 NS	-0,026844 NS	-0,021598 NS														
K	-0,04774 **	-0,022598 NS	-0,010809 NS	0,01079 NS	0,00704 NS	0,020191 NS	0,005858 NS	0,011345 NS													
Mg	-0,007163 NS	0,041145 **	-0,003075 NS	0,01637 NS	-0,00344 NS	0,028355 NS	0,007338 NS	0,00747 NS	0,022357 NS												
Mn	-0,009824 NS	-0,026026 NS	0,009025 NS	0,06041 **	0,133639 **	-0,028416 *	-0,009526 NS	0,023275 NS	0,020864 NS	0,040748 *											
pH	-0,012585 NS	0,016324 NS	-0,0076 NS	0,016281 NS	0,028354 NS	0,019093 NS	0,017355 NS	-0,006989 NS	-0,004712 NS	0,00869 NS	-0,013787 NS										
Zn	-0,022004 NS	0,010765 NS	0,001471 NS	0,006217 NS	-0,011906 NS	0,019197 NS	-0,010794 NS	-0,000617 NS	0,02871 *	-0,009286 NS	0,009267 NS	-0,011358 NS									
Argila	-0,043304 **	0,06212 NS	-0,039841 **	-0,115024 **	-0,262297 **	0,104711 **	0,005173 NS	-0,015989 NS	0,038407 **	-0,104073 **	-0,015522 NS	0,032763 *	0,284786 **								
Areia	0,02561 NS	-0,065677 **	0,033052 *	0,105844 **	0,218127 **	-0,092767 **	-0,001901 NS	0,02958 *	-0,035005 *	0,089697 **	0,010523 NS	-0,025839 NS	-0,251381 **	0,22187 **							
Silte	0,055219 **	-0,032164 *	0,035374 *	0,085189 **	0,232036 **	-0,083383 **	-0,00848 NS	-0,012327 NS	-0,028992 NS	0,086946 **	0,017607 NS	-0,031272 *	-0,228273 **	0,197859 **	0,188889 **						
RSP_0_10	0,010597 NS	0,039909 **	-0,008084 NS	-0,012505 NS	-0,042463 *	0,026877 NS	-0,003621 NS	-0,011277 NS	0,032524 *	-0,007637 NS	0,003507 NS	0,021355 NS	0,093911 **	-0,087291 **	-0,068129 **	0,010627 NS					
RSP_0_20	-0,00492 NS	0,042796 **	-0,006081 NS	-0,026717 NS	-0,091665 **	0,074074 *	-0,011896 NS	-0,007599 NS	0,035815 *	-0,018608 NS	0,008979 NS	0,019728 NS	0,127718 **	-0,112801 **	-0,10227 **	0,021151 NS	0,028604 NS				
RSP_10_20	-0,019584 NS	0,036648 **	-0,002935 NS	-0,035574 **	-0,122045 **	0,037757 **	-0,017132 NS	-0,002431 NS	0,031233 *	-0,025932 NS	0,012089 NS	0,014539 NS	0,134573 **	-0,114416 **	-0,114974 **	0,026646 NS	0,029533 *	0,026856 NS			
Altitude	0,053519 **	-0,057183 **	-0,004922 NS	0,010133 NS	0,119118 **	-0,060302 **	0,019062 NS	-0,033146 *	-0,070797 **	-0,000714 NS	-0,017411 NS	-0,053454 **	-0,166869 **	0,142259 **	0,141944 **	-0,077645 **	-0,097091 **	-0,095625 **	0,185601 **		
	Prod.	P	Ca	C	Cu	Fe	H+AL	K	Mg	Mn	pH	Zn	Argila	Areia	Silte	RSP_0_10	RSP_0_20	RSP_10_20	Altitude		

* p-valor significativo a 5% de probabilidade, ** p-valor significativo a 1% de probabilidade, NS = não significativo (p-valor > 0,05); Prod.: Produtividade.

5.3 Delineamento das unidades de manejo

A partir das variáveis que possuíam autocorrelação espacial e ao mesmo tempo correlacionadas espacialmente com a produtividade (Cu, argila, silte e altitude), iniciou-se o processo de geração das unidades de manejo através do software FuzME. Fizeram-se diferentes combinações das variáveis selecionadas para gerar as unidades de manejo. Inicialmente, de forma decrescente, as variáveis selecionadas foram ordenadas com base nos valores da estatística de correlação cruzada, absolutos correlacionados com a produtividade (Tabela 2). Neste caso há: Cu ($|0,09284|$), silte ($|0,05522|$), altitude ($|0,05351|$) e argila ($|0,04330|$). As quatro primeiras combinações de unidades de manejo (delineamentos) 01-CuSiAlAr, 02-CuSiAl, 03-CuSi e 04-Cu (Tabela 3) seguem a lógica de utilizar todas as variáveis selecionadas na primeira combinação (01-CuSiAlAr). Retira-se, de forma ordenada, a última variável que tem menor correlação espacial com a produtividade, a cada combinação de variáveis subsequentes, até que reste a variável mais correlacionada espacialmente (04-Cu). O segundo passo consistiu em organizar as unidades de manejo fazendo-se as combinações das variáveis selecionadas de forma que contemple todas as possibilidades de interação entre as variáveis. Assim, foi possível ter os delineamentos 5 a 15 (Tabela 3).

Tabela 3 Combinação de variáveis para gerar unidades de manejo

Delineamentos	Siglas	Atributos
1	01-CuSiAlAr	Cobre, Silte, Altitude e Argila
2	02-CuSiAl	Cobre, Silte e Altitude
3	03-CuSi	Cobre e Silte
4	04-Cu	Cobre
5	05-CuSiAr	Cobre, Silte e Argila
6	06-CuAlAr	Cobre, Altitude e Argila
7	07-SiAlAr	Silte, Altitude e Argila
8	08-CuAl	Cobre e Altitude
9	09-CuAr	Cobre e Argila
10	10-SiAl	Silte e Altitude
11	11-SiAr	Silte e Argila
12	12-ArAl	Argila e Altitude
13	13-Si	Silte
14	14-Al	Altitude
15	15-Ar	Argila

Cu: cobre; Si: silte; Al: altitude; Ar: argila.

Depois que os dados de cada delineamento foram classificados pelo FuzME, geraram-se os mapas temáticos de valores pontuais, isto é, não interpolados, com os dados da classificação de cada ponto nas diferentes classes de unidades de manejo, sendo que cada delineamento foi dividido em duas, três, quatro e cinco classes (Figuras 5 a 8).

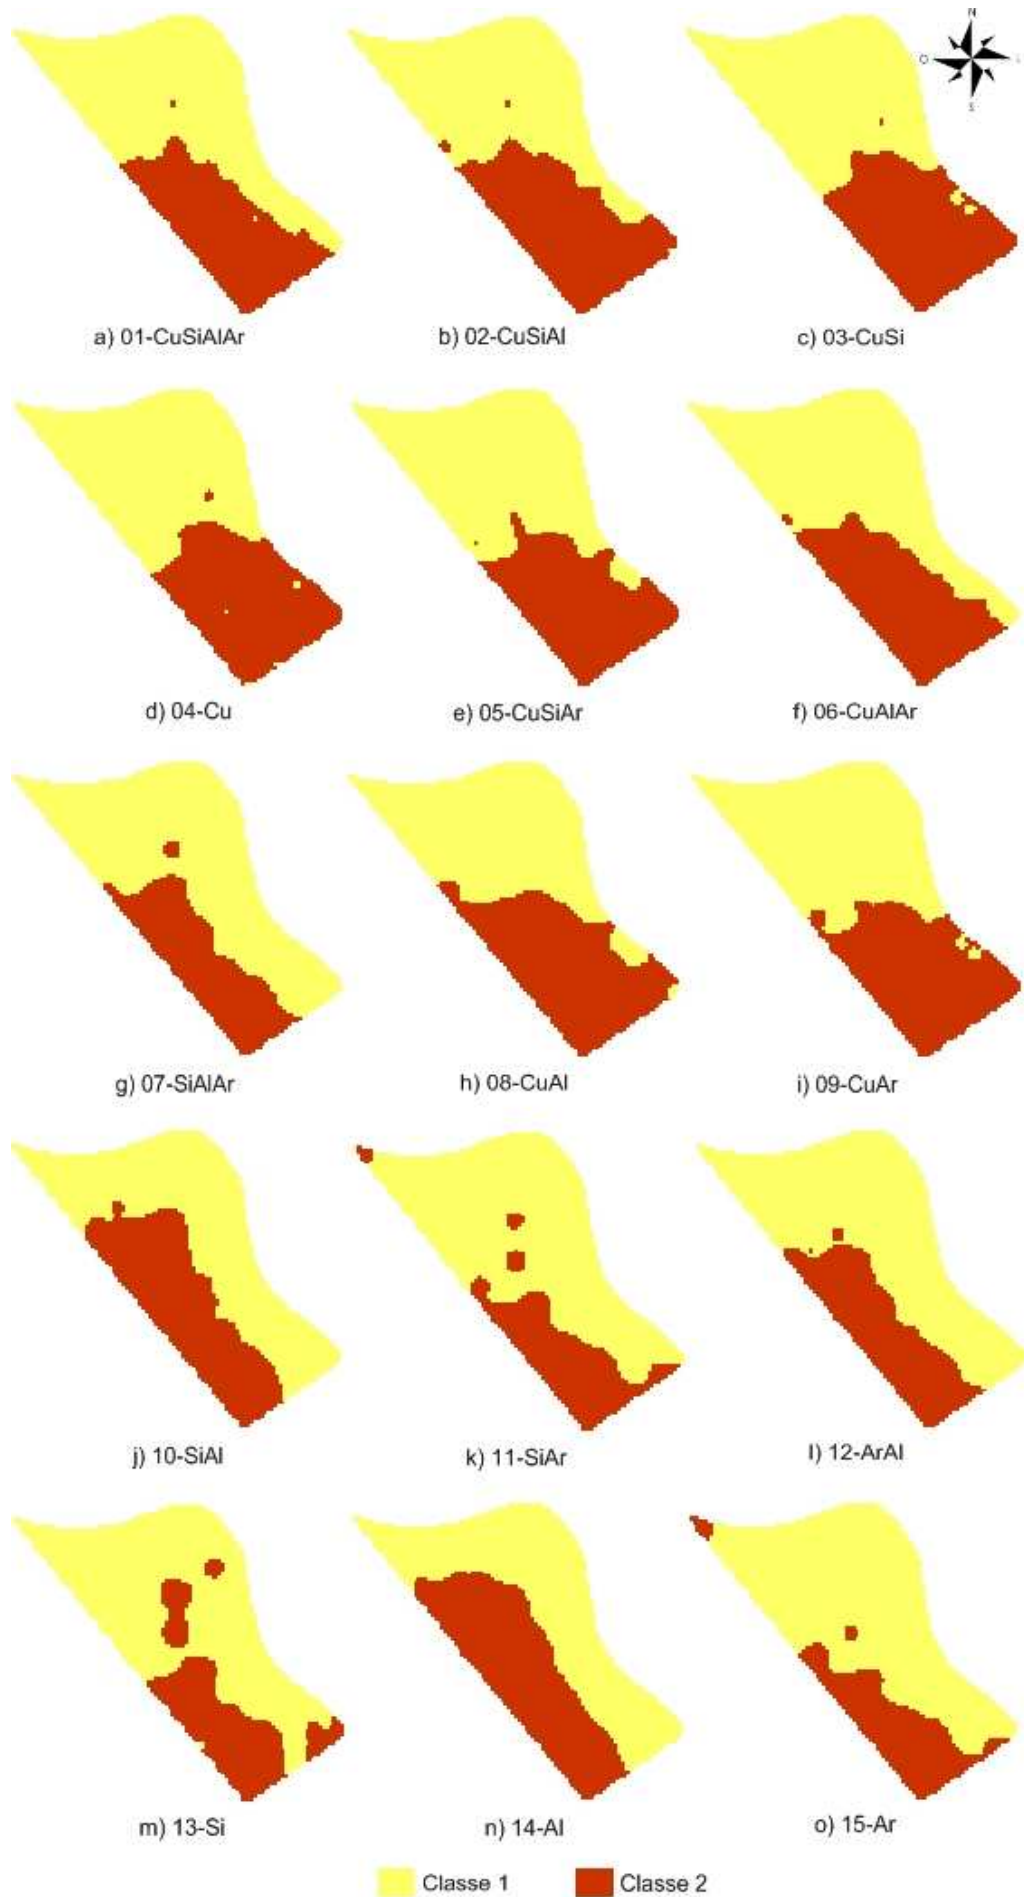


Figura 5 Divisão da área em unidades de manejo com duas classes.

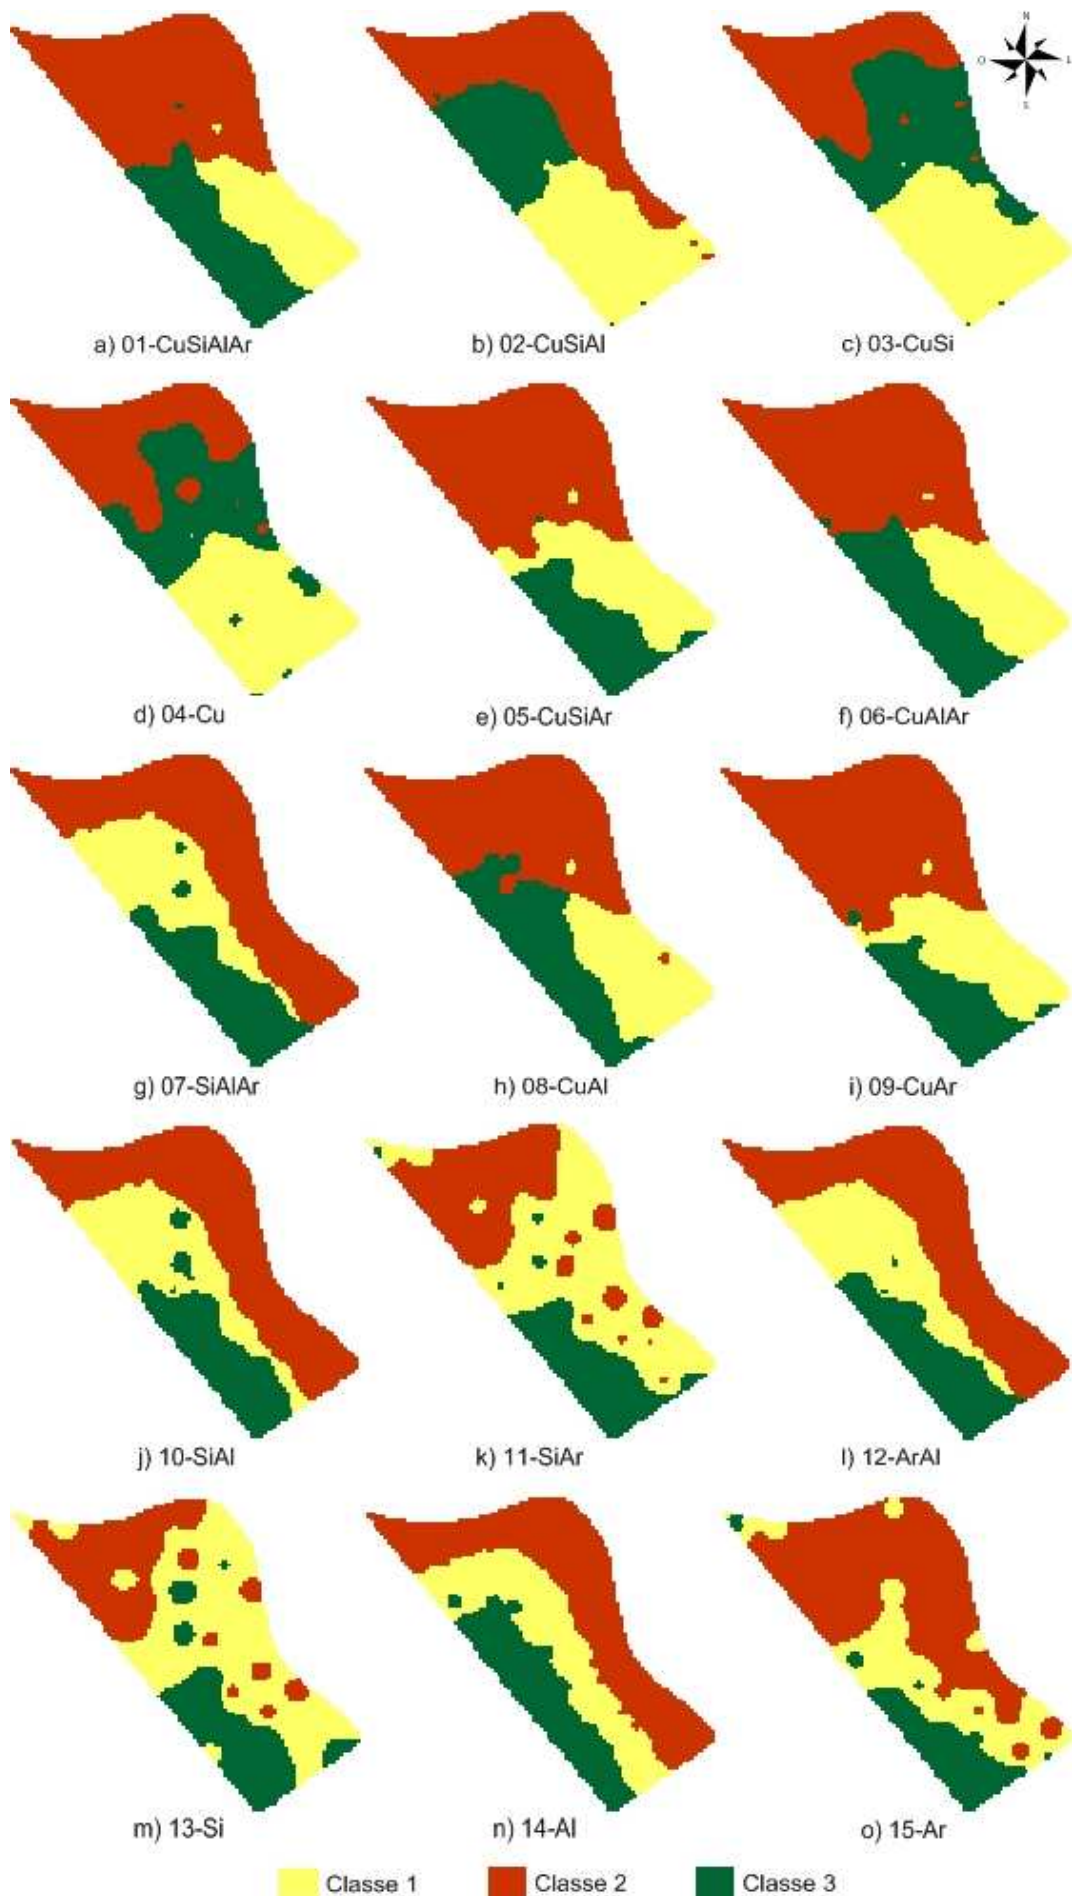


Figura 6 Divisão da área em unidades de manejo com três classes.

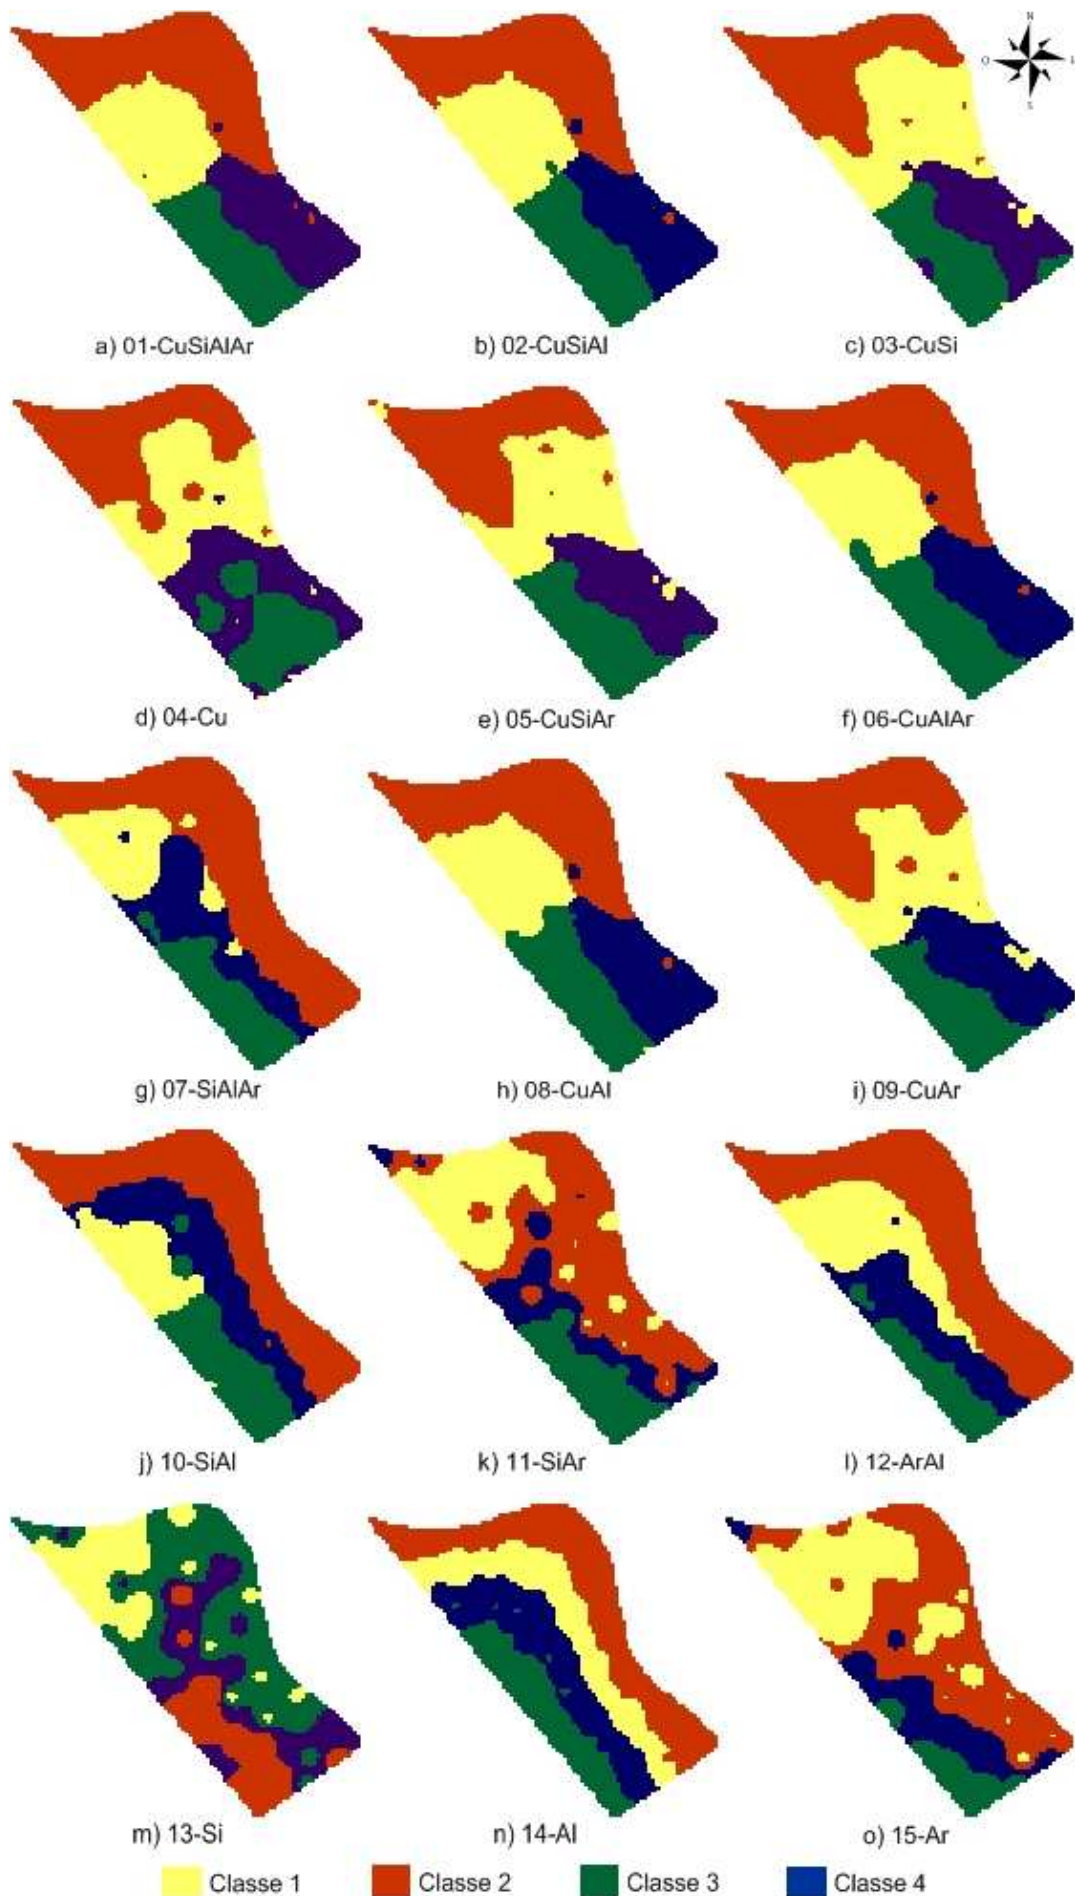


Figura 7 Divisão da área em unidades de manejo com quatro classes.

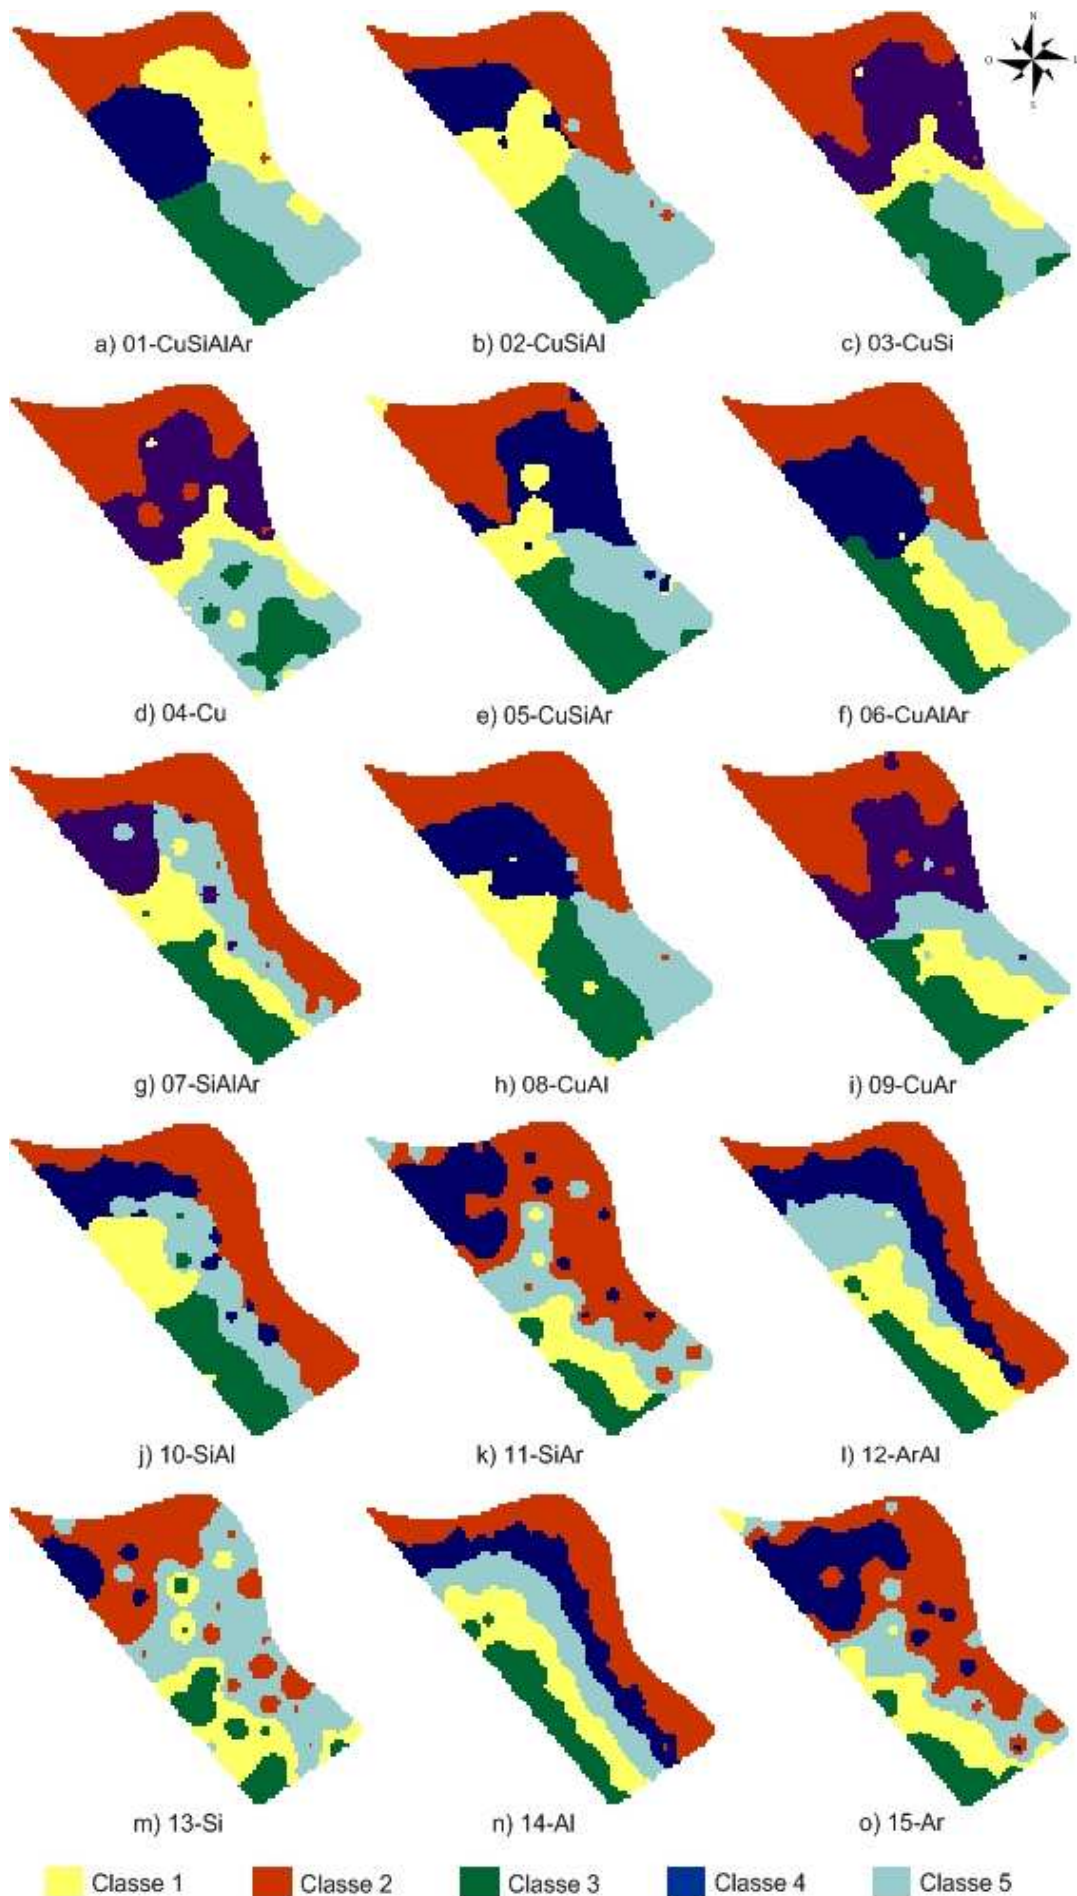


Figura 8 Divisão da área em unidades de manejo com cinco classes.

Percebe-se que existem semelhanças entre divisões de algumas unidades de manejo, pela interpretação visual dos mapas de unidades de manejo. Os grupos de unidades de manejo semelhantes (Tabela 4) são separados em função das divisões em 2, 3, 4 e 5 (Figuras 5 a 8).

Tabela 4 Grupos de unidades de manejo semelhantes visualmente

Divisão	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
2 classes	01-CuSiAlAr				
	02-CuSiAl				
	03-CuSi				
	04-Cu	10-SiAl	11-SiAr		
	05-CuSiAr	12-ArAl	13-Si		
	06-CuAlAr	14-Al	15-Ar		
	08-CuAl				
	09-CuAr				
	3 classes	07-SiAlAr	01-CuSiAlAr	05-CuSiAr	11-SiAr
10-SiAl		06-CuAlAr	09-CuAr	13-Si	04-Cu
12-ArAl		08-CuAl		15-Ar	
14-Al					
4 classes	01-CuSiAlAr	03-CuSi	10-SiAl	11-SiAr	
	02-CuSiAl	04-Cu	12-ArAl	13-Si	
	06-CuAlAr	05-CuSiAr	14-Al	15-Ar	
	08-CuAl	09-CuAr			
5 classes	02-CuSiAl	03-CuSi	07-SiAlAr		
	08-CuAl	09-CuAr	12-ArAl		
			14-Al		

Os delineamentos 11-SiAr, 13-Si e 15-Ar (Figuras 6 (k, m, o), 7 (k, m, o) e 8 (k, m, o)) divididos em 3, 4 e 5 classes apresentaram pequenos agrupamentos de uma mesma classe em locais dispersos na área. Isso, na prática, inviabiliza a utilização desses delineamentos para se trabalhar com unidades de manejo.

5.4 Avaliação das unidades de manejo

Nenhuma das unidades de manejo apresentou valores de ER menor do que um (Tabelas de 5 a 19). Entretanto, as unidades de manejo 11-SiAr com 2 classes (Tabela 15), 13-Si com 2, 3 e 4 classes (Tabela 17) e a 15-Ar com 2 classes (Tabela 19) apresentaram eficiência relativa igual a 1, ou seja, estas formas de divisão em UM não contribuirão para a diminuição da variância da produtividade. As demais unidades de manejo, com $ER > 1$, apresentaram redução da variância, sugerindo que a divisão pode ser utilizada como fonte de recomendação e análise. A divisão em unidades de manejo 09-CuAr em 5 classes (Tabela 13) foi a que apresentou maior ER (1,16) dentre todas as UM. Considerando a divisão em 4 UM, os delineamentos 04-Cu (Tabela 8) e 09-CuAr (Tabela 13) apresentaram-se melhores na redução da variância da produtividade, com $ER = 1,13$. Os delineamentos

01-CuSiAlAr (Tabela 5) e 06-CuAlAr (Tabela 10) apresentaram maior valor de ER (1,12) do que nas outras divisões em 3 classes. Já nas divisões em 2 classes, o delineamento 04-Cu (Tabela 8) foi o que apresentou maior valor de ER (1,10). Verificou-se que os maiores valores de ER foram encontrados em divisões com maiores números de classes.

As produtividades para os delineamentos 01-CuSiAlAr (Tabela 5), 02-CuSiAl (Tabela 6), 03-CuSi (Tabela 7), 04-Cu (Tabela 8), 05-CuSiAr (Tabela 9), 06-CuAlAr (Tabela 10), 07-SiAlAr (Tabela 11), 08-CuAl (Tabela 12), 09-CuAr (Tabela 13) e 12-ArAl (Tabela 16) somente apresentaram médias significativamente diferentes entre si para a divisão em 2 classes. Nos delineamentos restantes, não houve divisões em que todas as médias foram significativamente diferentes. Arno et al. (2011) também identificaram, através da ANOVA, que as diferenças de produtividade entre os anos avaliados foram evidentes apenas quando a área foi subdividida em duas unidades de manejo. Quando divididas em 3 ou 4 unidades de manejo, nem todas as classes corresponderam às regiões de menor e maior produtividade entre os anos estudados.

Nos boxplots dos dados de produtividade da soja são apresentadas as diferenças em cada classe de UM nos 15 delineamentos visando mostrar a distribuição espacial dos dados de produtividade em cada classe. Somente um boxplot é apresentado no corpo da dissertação (Figura 9) já que os outros estão apresentados no anexo (ANEXO A), pois, não são necessárias as discussões feitas no texto.

Tabela 5 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 01-CuSiAlAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	59	77	2,09	3,18 a	4,64	16,02 (m)	0,15	0,18	0,26	1,06
	2	41	53	2,43	3,44 b	4,55	14,54 (m)				
3 classes	2	47	61	2,09	3,10 a	4,08	15,15 (m)	0,11	0,12	0,24	1,12
	1	22	29	2,45	3,45 b	4,64	16,16 (m)				
	3	31	40	2,43	3,46 b	4,47	13,79 (m)				
4 classes	2	35	46	2,09	3,06 a	4,64	17,96 (m)	0,12	0,12	0,25	1,10
	1	19	25	2,80	3,34 ab	4,17	10,52 (m)				
	4	22	28	2,45	3,39 b	4,55	15,91 (m)				
	3	24	31	2,43	3,48 b	4,47	13,51 (m)				
5 classes	4	22	29	2,09	3,00 a	4,08	16,92 (m)	0,15	0,14	0,24	1,11
	1	18	24	2,16	3,19 ab	4,64	16,91 (m)				
	5	17	22	2,80	3,35 ab	4,17	10,62 (m)				
	3	19	25	2,43	3,43 b	4,55	16,37 (m)				
	2	23	30	2,50	3,48 b	4,47	13,59 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.




Figura 9 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 01-CuSiAlAr com 2, 3, 4 e 5 classes.

Tabela 6 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 02-CuSiAl

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	52	68	2,09	3,14 a	4,64	16,26 (m)	0,15	0,18	0,25	1,09
	2	48	62	2,43	3,45 b	4,55	14,07 (m)				
3 classes	2	41	53	2,09	3,10 a	4,64	17,70 (m)	0,15	0,16	0,25	1,09
	1	39	51	2,43	3,46 b	4,55	14,84 (m)				
	4	35	45	2,09	3,07 a	4,64	18,05 (m)				
4 classes	1	19	25	2,73	3,29 ab	4,17	10,56 (m)	0,11	0,11	0,25	1,10
	3	23	30	2,45	3,42 b	4,55	15,51 (m)				
	2	23	30	2,43	3,48 b	4,47	13,80 (m)				
5 classes	5	32	41	2,09	3,09 a	4,64	18,54 (m)	0,14	0,13	0,25	1,07
	1	12	15	2,68	3,16 a	3,60	11,32 (m)				
	2	14	18	2,80	3,40 a	4,17	10,72 (m)				
	3	22	28	2,43	3,42 a	4,47	15,20 (m)				
	4	22	28	2,45	3,44 a	4,55	15,04 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 7 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 03-CuSi

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	55	71	2,09	3,15 a	4,64	15,80 (m)	0,06	0,07	0,25	1,08
	2	45	59	2,43	3,45 b	4,55	14,69 (m)				
	3	31	40	2,09	3,03 a	4,08	15,41 (m)				
3 classes	1	30	39	2,16	3,34 b	4,64	15,28 (m)	0,09	0,09	0,24	1,11
	2	39	51	2,43	3,45 b	4,55	14,55 (m)				
	3	28	37	2,09	3,04 a	4,08	15,76 (m)				
4 classes	2	28	37	2,16	3,29 ab	4,64	14,66 (m)	0,09	0,09	0,25	1,10
	1	23	30	2,43	3,35 ab	4,47	15,48 (m)				
	4	20	26	2,45	3,55 b	4,55	14,33 (m)				
5 classes	1	25	32	2,09	3,01 a	3,84	15,42 (m)	0,10	0,09	0,25	1,10
	4	24	31	2,16	3,23 ab	4,17	13,60 (m)				
	2	22	28	2,50	3,39 ab	4,47	14,85 (m)				
	3	18	23	2,43	3,48 b	4,55	15,23 (m)				
	5	12	16	2,78	3,48 b	4,64	16,90 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 8 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 04-Cu

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	55	71	2,09	3,14 a	4,64	15,74 (m)	0,04	0,05	0,25	1,10
	2	45	59	2,43	3,46 b	4,55	14,47 (m)				
3 classes	3	32	41	2,09	3,04 a	4,08	15,75 (m)	0,06	0,07	0,24	1,11
	1	28	37	2,16	3,34 b	4,64	14,23 (m)				
	2	40	52	2,43	3,45 b	4,55	15,09 (m)				
4 classes	3	28	36	2,09	3,04 a	4,08	16,28 (m)	0,07	0,07	0,24	1,13
	2	28	36	2,16	3,26 a	4,64	14,77 (m)				
	1	22	29	2,43	3,33 ab	4,55	15,79 (m)				
	4	22	29	2,80	3,58 b	4,47	12,68 (m)				
5 classes	2	27	35	2,09	3,05 a	4,08	16,36 (m)	0,07	0,06	0,24	1,12
	4	22	29	2,16	3,21 ab	4,17	13,47 (m)				
	3	12	15	2,43	3,22 ab	4,55	18,64 (m)				
	1	15	20	2,68	3,50 b	4,64	15,33 (m)				
	5	24	31	2,91	3,52 b	4,47	12,72 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 9 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 05-CuSiAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	2	57	74	2,09	3,17 a	4,64	16,11 (m)	0,09	0,11	0,25	1,07
	1	43	56	2,43	3,45 b	4,55	14,37 (m)				
3 classes	3	51	66	2,09	3,12 a	4,17	15,21 (m)	0,09	0,10	0,24	1,11
	1	26	34	2,43	3,41 b	4,47	14,56 (m)				
	2	23	30	2,45	3,52 b	4,64	15,17 (m)				
4 classes	3	28	37	2,09	3,03 a	3,84	14,63 (m)	0,11	0,11	0,25	1,10
	1	28	36	2,16	3,30 ab	4,64	15,64 (m)				
	2	25	33	2,43	3,41 b	4,47	14,72 (m)				
	4	18	24	2,45	3,49 b	4,55	15,44 (m)				
5 classes	3	25	33	2,09	3,02 a	3,84	14,80 (m)	0,13	0,12	0,25	1,09
	2	8	10	2,30	3,24 ab	3,65	12,66 (m)				
	1	23	30	2,16	3,30 ab	4,64	16,36 (m)				
	4	25	33	2,43	3,41 ab	4,47	14,72 (m)				
	5	18	24	2,45	3,49 b	4,55	15,44 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 10 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 06-CuAlAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	58	75	2,09	3,16 a	4,64	15,85 (m)	0,14	0,17	0,25	1,08
	2	42	55	2,43	3,46 b	4,55	14,48 (m)				
3 classes	2	47	61	2,09	3,10 a	4,08	15,19 (m)	0,10	0,11	0,24	1,12
	1	24	31	2,43	3,39 b	4,64	17,49 (m)				
	3	29	38	2,68	3,51 b	4,47	12,23 (m)				
4 classes	3	34	44	2,09	3,07 a	4,64	18,23 (m)	0,11	0,11	0,25	1,10
	4	18	24	2,73	3,31 ab	4,17	11,38 (m)				
	2	23	30	2,43	3,35 ab	4,55	16,56 (m)				
	1	25	32	2,68	3,51 b	4,47	12,10 (m)				
5 classes	4	33	43	2,09	3,04 a	4,08	16,83 (m)	0,12	0,11	0,24	1,14
	5	18	23	2,73	3,28 ab	4,17	10,92 (m)				
	1	12	15	2,43	3,31 ab	3,95	15,15 (m)				
	2	18	24	2,45	3,45 b	4,64	17,29 (m)				
	3	19	25	2,68	3,55 b	4,47	11,99 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 11 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 07-SiAlAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	67	87	2,09	3,21 a	4,64	16,54 (m)	0,09	0,11	0,26	1,04
	2	33	43	2,43	3,45 b	4,47	13,55 (m)				
3 classes	2	52	68	2,09	3,19 a	4,64	18,06 (m)	0,12	0,13	0,26	1,03
	3	20	26	2,73	3,30 a	4,17	11,33 (m)				
	1	28	36	2,43	3,45 a	4,47	13,57 (m)				
4 classes	3	48	62	2,09	3,20 a	4,64	18,49 (m)	0,13	0,13	0,26	1,04
	4	14	18	2,68	3,21 a	3,80	11,47 (m)				
	2	18	23	2,43	3,30 a	4,17	13,73 (m)				
	1	21	27	2,68	3,52 a	4,47	12,09 (m)				
5 classes	2	38	49	2,09	3,14 a	4,64	17,61 (m)	0,16	0,14	0,26	1,06
	4	13	17	2,68	3,19 a	3,80	11,75 (m)				
	5	16	21	2,43	3,34 a	4,17	13,81 (m)				
	3	15	19	2,16	3,40 a	4,55	17,42 (m)				
	1	18	24	2,68	3,51 a	4,47	12,85 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 12 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 08-CuAl

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	2	52	68	2,09	3,14 a	4,64	16,16 (m)	0,15	0,17	0,25	1,09
	1	48	62	2,43	3,45 b	4,55	14,17 (m)				
3 classes	3	43	56	2,09	3,10 a	4,64	16,65 (m)	0,11	0,11	0,25	1,10
	2	27	35	2,43	3,34 ab	4,55	16,02 (m)				
	1	30	39	2,68	3,50 b	4,47	12,08 (m)				
4 classes	3	34	44	2,09	3,07 a	4,64	18,23 (m)	0,11	0,11	0,25	1,10
	4	18	24	2,73	3,28 ab	4,17	10,70 (m)				
	2	24	31	2,43	3,36 ab	4,55	16,73 (m)				
	1	24	31	2,68	3,52 b	4,47	11,89 (m)				
5 classes	3	32	42	2,09	3,07 a	4,64	18,48 (m)	0,11	0,10	0,25	1,07
	1	15	19	2,68	3,27 a	3,80	9,82 (b)				
	4	21	27	2,43	3,41 a	4,47	14,59 (m)				
	5	12	16	2,68	3,41 a	4,17	13,36 (m)				
	2	20	26	2,45	3,44 a	4,55	15,56 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 13 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 09-CuAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	55	72	2,09	3,15 a	4,64	15,77 (m)	0,07	0,09	0,25	1,08
	2	45	58	2,43	3,45 b	4,55	14,59 (m)				
3 classes	1	52	67	2,09	3,13 a	4,17	15,17 (m)	0,08	0,09	0,25	1,10
	3	24	31	2,43	3,42 b	4,47	14,82 (m)				
	2	25	32	2,45	3,49 b	4,64	15,28 (m)				
4 classes	4	32	41	2,09	3,01 a	3,84	14,90 (m)	0,11	0,10	0,24	1,13
	1	25	32	2,16	3,36 b	4,64	14,56 (m)				
	3	23	30	2,43	3,43 b	4,47	15,00 (m)				
	2	21	27	2,45	3,46 b	4,55	15,12 (m)				
5 classes	1	31	40	2,09	3,02 a	3,84	14,84 (m)	0,13	0,11	0,23	1,16
	4	21	27	2,16	3,26 ab	4,17	14,28 (m)				
	2	13	17	2,43	3,27 ab	4,55	18,02 (m)				
	5	20	26	2,68	3,52 b	4,47	12,82 (m)				
	3	15	20	2,80	3,56 b	4,64	14,57 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 14 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 10-SiAl

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	2	59	77	2,09	3,22 a	4,64	17,42 (m)	0,10	0,12	0,27	1,02
	1	41	53	2,43	3,39 a	4,47	13,08 (m)				
3 classes	1	53	69	2,09	3,19 a	4,64	18,01 (m)	0,12	0,13	0,26	1,06
	2	22	28	2,43	3,26 ab	3,95	12,24 (m)				
	3	25	33	2,68	3,51 b	4,47	12,23 (m)				
4 classes	4	42	54	2,09	3,12 a	4,64	17,05 (m)	0,13	0,13	0,25	1,07
	2	12	15	2,73	3,27 ab	4,17	12,78 (m)				
	3	23	30	2,16	3,37 ab	4,55	16,64 (m)				
	1	24	31	2,68	3,50 b	4,47	12,11 (m)				
5 classes	3	38	49	2,09	3,17 a	4,64	18,25 (m)	0,13	0,12	0,26	1,05
	5	15	19	2,31	3,18 a	4,28	17,56 (m)				
	2	11	14	2,80	3,31 a	4,17	12,23 (m)				
	1	15	20	2,43	3,32 a	3,97	13,65 (m)				
	4	22	28	2,68	3,52 a	4,47	11,96 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 15 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 11-SiAr

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	69	90	2,09	3,25 a	4,64	16,31 (m)	0,06	0,07	0,27	1,00
	2	31	40	2,30	3,37 a	4,47	14,69 (m)				
3 classes	1	33	43	2,31	3,12 a	4,11	14,55 (m)	0,10	0,10	0,26	1,04
	3	39	51	2,09	3,34 ab	4,64	17,20 (m)				
	2	28	36	2,43	3,42 b	4,47	13,97 (m)				
4 classes	4	25	32	2,31	3,09 a	4,11	14,56 (m)	0,12	0,11	0,25	1,07
	3	14	18	2,30	3,17 ab	3,92	13,89 (m)				
	1	39	51	2,09	3,33 ab	4,64	17,37 (m)				
	2	22	29	2,68	3,50 b	4,47	12,92 (m)				
5 classes	5	20	26	2,31	3,07 a	3,80	13,55 (m)	0,11	0,10	0,26	1,06
	4	15	20	2,30	3,23 ab	3,95	13,78 (m)				
	2	15	19	2,43	3,27 ab	4,47	15,43 (m)				
	1	38	49	2,09	3,33 ab	4,64	17,78 (m)				
	3	12	16	2,68	3,58 b	4,18	11,78 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 16 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 12-ArAl

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	66	86	2,09	3,21 a	4,64	16,64 (m)	0,09	0,11	0,26	1,03
	2	34	44	2,43	3,43 b	4,47	13,53 (m)				
3 classes	3	52	67	2,09	3,20 a	4,64	18,04 (m)	0,10	0,10	0,26	1,03
	1	22	29	2,43	3,28 a	4,17	12,16 (m)				
	2	26	34	2,50	3,46 a	4,47	13,27 (m)				
4 classes	2	51	66	2,09	3,20 a	4,64	18,18 (m)	0,12	0,11	0,26	1,03
	4	18	23	2,68	3,25 a	3,80	9,94 (b)				
	1	15	20	2,43	3,39 a	4,47	15,69 (m)				
	3	16	21	2,68	3,51 a	4,18	11,98 (m)				
5 classes	5	21	27	2,16	3,14 a	4,55	19,64 (m)	0,14	0,12	0,26	1,04
	1	32	42	2,09	3,22 a	4,64	17,10 (m)				
	3	15	19	2,73	3,27 a	3,80	9,64 (b)				
	2	18	23	2,43	3,39 a	4,47	14,61 (m)				
	4	15	19	2,68	3,53 a	4,18	12,09 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 17 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 13-Si

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	69	90	2,09	3,26 a	4,64	16,41 (m)	0,07	0,09	0,27	1,00
	2	31	40	2,34	3,35 a	4,47	14,61 (m)				
3 classes	2	28	37	2,31	3,18 a	4,37	16,03 (m)	0,08	0,08	0,27	1,00
	1	42	55	2,09	3,31 a	4,64	16,39 (m)				
	3	29	38	2,34	3,35 a	4,47	14,81 (m)				
4 classes	1	24	31	2,31	3,17 a	4,11	15,40 (m)	0,08	0,08	0,27	1,00
	3	36	47	2,09	3,29 a	4,64	18,45 (m)				
	2	19	25	2,50	3,33 a	4,47	14,31 (m)				
	4	21	27	2,34	3,37 a	4,02	12,67 (m)				
5 classes	3	6	8	2,33	2,92 a	3,60	15,08 (m)	0,09	0,07	0,26	1,03
	1	29	38	2,30	3,20 ab	4,37	16,06 (m)				
	5	16	21	2,34	3,27 ab	4,02	13,90 (m)				
	2	35	45	2,09	3,38 ab	4,64	16,00 (m)				
	4	14	18	2,68	3,42 b	4,47	15,61 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 18 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 14-AI

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	55	72	2,09	3,21 a	4,64	17,81 (m)	0,07	0,08	0,27	1,02
	2	45	58	2,43	3,38 a	4,47	12,88 (m)				
3 classes	3	49	64	2,09	3,18 a	4,64	18,06 (m)	0,08	0,08	0,26	1,05
	2	23	30	2,43	3,28 ab	4,28	12,86 (m)				
	1	28	36	2,68	3,48 b	4,47	12,79 (m)				
4 classes	1	38	49	2,09	3,14 a	4,64	17,06 (m)	0,07	0,06	0,26	1,05
	2	18	24	2,43	3,27 a	3,80	11,72 (m)				
	3	18	23	2,16	3,34 a	4,55	18,78 (m)				
	4	26	34	2,68	3,47 a	4,47	13,14 (m)				
5 classes	3	35	45	2,09	3,15 a	4,64	17,03 (m)	0,07	0,06	0,26	1,04
	4	15	20	2,43	3,21 a	3,88	13,97 (m)				
	5	17	22	2,16	3,30 a	4,55	19,87 (m)				
	2	15	19	2,92	3,39 a	4,47	11,09 (m)				
	1	18	24	2,68	3,50 a	4,18	12,89 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

Tabela 19 Estatística descritiva, eficiência relativa, FPI e MPE dos dados de produtividade na divisão com as variáveis 15-Ar

Divisão	Classes	Área da UM (%)	N	Mínimo	Média	Máximo	CV (%)	FPI	MPE	Var. Total	ER
2 classes	1	69	90	2,09	3,25 a	4,64	16,24 (m)	0,04	0,05	0,27	1,00
	2	31	40	2,30	3,37 a	4,47	14,90 (m)				
3 classes	1	55	72	2,09	3,15 a	4,37	15,04 (m)	0,08	0,08	0,25	1,08
	2	23	30	2,30	3,45 b	4,47	14,37 (m)				
	3	22	28	2,43	3,47 b	4,64	16,55 (m)				
4 classes	4	32	41	2,31	3,09 a	3,97	13,91 (m)	0,08	0,07	0,25	1,08
	2	17	22	2,30	3,23 ab	4,47	16,32 (m)				
	1	38	49	2,09	3,39 ab	4,64	16,72 (m)				
	3	14	18	2,68	3,53 b	4,18	12,01 (m)				
5 classes	2	20	26	2,31	3,08 a	3,80	13,44 (m)	0,08	0,06	0,25	1,09
	3	14	18	2,30	3,18 ab	4,47	17,32 (m)				
	5	38	49	2,09	3,25 ab	4,64	17,38 (m)				
	4	15	20	2,56	3,53 b	4,28	12,33 (m)				
	1	13	17	2,68	3,55 b	4,18	12,14 (m)				

N: Quantidade de elementos amostrais; CV: Coeficiente de Variação - baixo (b), médio (m), alto (a), muito alto (ma); ER: Eficiência relativa; Var. Total: Variância total, obtida pela representatividade de cada unidade de manejo e a variância encontrada.

A eficiência relativa, em função do número de classes e do conjunto de variáveis utilizados, está apresentada na Figura 10. Percebe-se que não existe uma definição clara se houve aumento ou redução da eficiência da UM à medida que são retiradas as variáveis menos correlacionadas com a produtividade, com relação aos delineamentos 01-CuSiAlAr, 02-CuSiAl, 03-CuSi e 04-Cu. O delineamento 04-Cu, no qual foi utilizado apenas a variável Cu, que é mais correlacionada com a produtividade, apresentou ER maior na divisão em 2, 4 e 5 classes do que nos delineamentos 01-CuSiAlAr, 02-CuSiAl e 03-CuSi. Bons resultados de eficiência relativa também foram encontrados nos delineamentos 06-CuAlAr e 09-CuAr. Nas unidades de manejo que possuem a variável Cu em seu delineamento, os índices de ER apresentaram-se maiores do que as outras.




Figura 10 Eficiência relativa nas unidades de manejo.

De acordo com os baixos índices de ER (Figura 10) e com a não diferenciação das médias de produtividade apresentadas pela ANOVA (Tabelas 5 a 19) nas classes de unidades de manejo, verificou-se que as unidades de manejo se apresentaram menos eficazes quando a variável Cu não estava envolvida, no caso foram 07-SiAlAr, 10-SiAl, 11-SiAr, 12-ArAl, 13-Si, 14-Al e 15-Ar.

O índice de desempenho fuzzy (FPI: *Fuzziness Performance Index*) e o índice da partição da entropia modificada (MPE: *Modified Partition Entropy*) foram utilizados para verificar se as classificações de UM, apontadas por eles com melhores níveis de separação e organização dos dados, também correspondem às classificações com melhores índices de ER (Figura 11). Vale ressaltar que a ER foi realizada sobre os dados de produtividade, já os índices FPI e MPE são sobre os dados das variáveis utilizadas em cada delineamento de UM.

Nas unidades de manejo, divididas em duas classes (Figura 11 (a)), percebe-se que o delineamento 04-Cu apresentou a maior separação e organização dos dados entre as classes, ou seja, menor valor de FPI (0,04) e MPE (0,05) e também com a maior ER (1,10). Apesar das unidades 02-CuSiAl e 08-CuAl apresentarem-se na sequência, com segunda e terceira melhor ER, os valores de FPI e MPE foram maiores, com menos separação e organização dos dados entre as classes. Nas unidades de manejo divididas em três classes (Figura 11 (b)), o menor valor de FPI (0,06) e MPE (0,07) encontrado foi para o

delineamento 04-Cu, que apresentou o terceiro maior valor de ER (1,11). Nas unidades de manejo, divididas em quatro classes (Figura 11 (c)), os delineamentos 04-Cu, 14-AI e 15-Ar apresentaram o menor valor de FPI (0,07) e MPE (0,07). O delineamento 04-Cu apresentou maior ER (1,13) junto com o delineamento 09-CuAr. Já os delineamentos 14-AI e 15-Ar tiveram ER mais baixas. Nas unidades de manejo, divididas em cinco classes (Figura 11 (d)), os delineamentos 04-Cu e 14-AI apresentaram menores valores de FPI (0,07) e MPE (0,06). O delineamento 04-Cu ficou com o terceiro melhor valor de ER (1,12).

Melhor separação e organização dos dados entre as classes são percebidas ao se utilizar menor quantidade de variáveis na classificação em UM, ou seja, obtêm-se menores valores de FPI e MPE (Figura 11). Neste sentido, percebe-se que os delineamentos 04-Cu, 13-Si, 14-AI e 15-Ar, nos quais se utilizou apenas uma variável na divisão em unidades de manejo, foram aqueles que apresentaram menores índices de FPI e MPE. Entretanto, apenas o delineamento 04-Cu apresentou valor de ER alto. Os delineamentos 13-Si, 14-AI e 15-Ar apresentaram, de forma geral, valores mais baixos de ER.

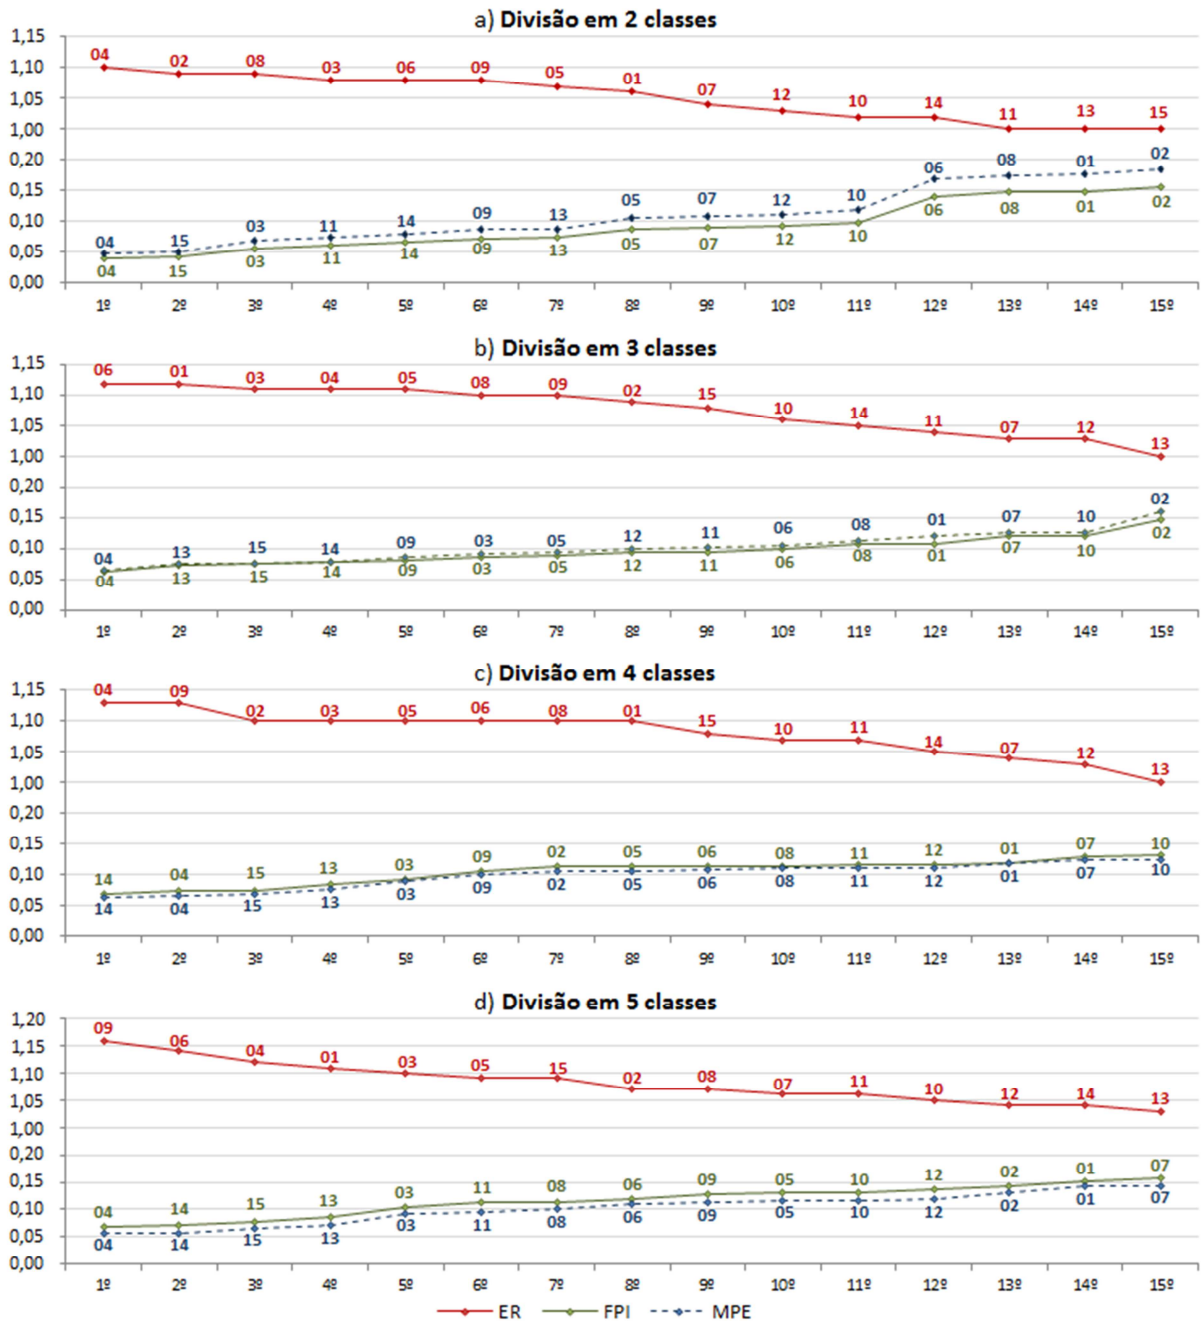


Figura 11 Gráfico de desempenho das divisões em unidade de manejo apontado pelos índices FPI, MPE e ER, em ordem decrescente para a ER e ordem crescente para FPI e MPE.

Os seis delineamentos de UM que se apresentaram relativamente mais eficazes (01-CuSiAlAr, 02-CuSiAl, 03-CuSi, 04-Cu, 06-CuAlAr e 09-CuAr), de acordo com a ER, foram comparados através do índice Kappa (Tabela 20) para verificar o grau de concordância visual entre os mapas de 2, 3, 4 e 5 classes.

Nas UM divididas em 2 classes, verificou-se que oito (8) comparações se apresentaram com concordância muito forte e sete (7) comparações se apresentaram com concordância forte. O delineamento 04-Cu, que teve o maior valor de ER, apresentou concordância muito forte com os delineamentos 03-CuSi e 09-CuAr, e concordância forte com os delineamentos 01-CuSiAlAr, 02-CuSiAl e 06-CuAlAr. Nas UM divididas em 3

classes, obtiveram-se quatro (4) comparações com concordância muito forte, duas (2) com concordância moderada e nove (9) com concordância fraca. Os delineamentos 01-CuSiAlAr e 06-CuAlAr, que tiveram maior ER, apresentaram concordância muito forte. Esses delineamentos também apresentaram concordância muito forte com o delineamento 09-CuAr. O delineamento 04-Cu teve concordância muito forte com o 03-CuSi. Nas UM divididas em 4 classes, quatro (4) comparações apresentaram concordância muito forte, cinco (5) apresentaram concordância forte, quatro (4) apresentaram concordância moderada e duas (2) apresentaram concordância fraca. Os delineamentos 04-Cu e 09-CuAr, que apresentaram maior ER dentre as divisões em 4 classes, tiveram concordância forte. O delineamento 04-Cu apresentou concordância forte com o delineamento 03-CuSi. O delineamento 09-CuAr apresentou concordância muito forte com o delineamento 03-CuSi. Nas UM divididas em 5 classes, duas (2) comparações apresentaram concordância forte, sete (7) apresentaram concordância moderada e seis (6) apresentaram concordância fraca. O delineamento 09-CuAr, com maior ER dentre as divisões em 5 classes, o máximo que teve foi concordância moderada com outros delineamentos (01-CuSiAlAr, 03-CuSi, 04-Cu e 06-CuAlAr). O delineamento 04-Cu teve concordância forte com o 03-CuSi.

Tabela 20 Índice Kappa entre os mapas de unidades de manejo, divididos em 2, 3, 4 e 5 classes nos delineamentos 01-CuSiAlAr, 02-CuSiAl, 03-CuSi, 04-Cu, 06-CuAlAr e 09-CuAr

Delineamentos comparados	2 classes	3 classes	4 classes	5 classes
01-CuSiAlAr x 02-CuSiAl	0,87 (MF)	0,31 (FR)	0,96 (MF)	0,59 (MO)
01-CuSiAlAr x 03-CuSi	0,72 (FO)	0,30 (FR)	0,61 (FO)	0,61 (FO)
01-CuSiAlAr x 04-Cu	0,69 (FO)	0,30 (FR)	0,42 (MO)	0,44 (MO)
01-CuSiAlAr x 06-CuAlAr	0,95 (MF)	0,97 (MF)	0,95 (MF)	0,35 (FR)
01-CuSiAlAr x 09-CuAr	0,76 (FO)	0,85 (MF)	0,64 (FO)	0,48 (MO)
02-CuSiAl x 03-CuSi	0,83 (MF)	0,56 (MO)	0,60 (MO)	0,38 (FR)
02-CuSiAl x 04-Cu	0,80 (FO)	0,56 (MO)	0,40 (FR)	0,25 (FR)
02-CuSiAl x 06-CuAlAr	0,89 (MF)	0,31 (FR)	0,93 (MF)	0,59 (MO)
02-CuSiAl x 09-CuAr	0,86 (MF)	0,33 (FR)	0,61 (FO)	0,29 (FR)
03-CuSi x 04-Cu	0,97 (MF)	0,90 (MF)	0,66 (FO)	0,71 (FO)
03-CuSi x 06-CuAlAr	0,74 (FO)	0,29 (FR)	0,57 (MO)	0,38 (FR)
03-CuSi x 09-CuAr	0,96 (MF)	0,33 (FR)	0,86 (MF)	0,59 (MO)
04-Cu x 06-CuAlAr	0,71 (FO)	0,29 (FR)	0,38 (FR)	0,29 (FR)
04-Cu x 09-CuAr	0,93 (MF)	0,34 (FR)	0,67 (FO)	0,48 (MO)
06-CuAlAr x 09-CuAr	0,78 (FO)	0,83 (MF)	0,60 (MO)	0,52 (MO)

MF: muito forte; FO: forte; MO: moderada; FR: fraca.

6 CONCLUSÕES

As unidades de manejo (UM) que utilizaram a variável Cu no seu delineamento se apresentaram, de forma geral, com índices de eficiência relativa maiores do que as outras.

O índice de desempenho fuzzy (FPI: *Fuzziness Performance Index*) e o índice da partição da entropia modificada (MPE: *Modified Partition Entropy*) apresentaram resultados equivalentes na seleção de variáveis a serem utilizadas na definição de UM. Entretanto, os resultados foram diferentes do índice eficiência relativa (ER).

Maior separação e organização das classes de UM, avaliadas pelos índices FPI e MPE, ocorreu quando foram utilizados delineamentos com menor número de variáveis no processo de classificação dos dados pelo algoritmo fuzzy C-means.

Não houve um aumento ou redução de forma ordenada da eficiência relativa, no processo de gerar UM partindo-se do pressuposto de utilizarem-se todas as variáveis correlacionadas com a produtividade e retirando-se a menos correlacionada, até ficar a mais correlacionada.

O delineamento 04-Cu apresentou os melhores resultados e a melhor ER na divisão em 2 e 4 classes.

Dentre todos os delineamentos de UM, no máximo, existem duas médias (classes) de produtividade, diferentes em cada delineamento, o que torna a divisão em duas classes a mais indicada.

7 REFERÊNCIAS

- AHRENS, A. B.; MIARA, C.; AHRENS, R. B. Agricultura de Precisão: uma ferramenta estratégica para gerenciar propriedades rurais. **Revista Innovare**, Ponta Grossa, n. 3, p. 01-07, jan./jul. 2007.
- ANGELICO, J. C.; SILVA, I. N. da. Eficiência da krigagem na estimativa das variáveis físicas e químicas do solo. **Energia na Agricultura**, Botucatu, v. 1, n. 21, p. 106-117, 2006.
- ANUAR, A. R.; GOH, K. J.; HEOH, T. B.; AHMED, O. H. Transforming Spatio-Temporal Yield Maps to Classified Management Zone Maps for Efficient Management of Oil Palm. **American Journal of Applied Sciences**, v. 5, n. 10, p. 1392-1396, 2008.
- ARAÚJO, J. C.; VETTORAZZI, C. A.; MOLIN, J. P. Estimativa da produtividade e determinação de zonas de manejo, em culturas de grãos, por meio de videografia aérea multiespectral. **Acta Science Agronomy**, Maringá, v. 27, n. 3, p. 347-447, 2005.
- ARCHELA, R. S.; THÉRY, H. Orientação metodológica para construção e leitura de mapas temáticos. **Confins** [Online], v. 3, n. 3, p. 2-21, 2008.
- ARNO, J.; MARTINEZ-CASASNOVAS, J. A.; RIBES-DASI, M.; ROSSEL, J. R. Clustering of grape yield maps to delineate site-specific. **Spanish Journal of Agricultural Research**, v. 9, n. 3, p. 721-729, 2011.
- BALASTREIRE, L. A. Potencial do Uso da Agricultura de Precisão no Brasil. In: Encontro Paulista de Soja, 2., 2000, Ituverava. **Anais do II Encontro Paulista de Soja**. Campinas: Departamento de Comunicação e Treinamento-DCT/CATI, 2000. p. 167-179.
- BARROS, L. C.; BASSANEZI, R. C. **Tópicos de lógica fuzzy e biomatemática**. Campinas: IMECC-UNICAMP, 2006. 354 p.
- BAZZI, C. L.; SOUZA, E. G. de; URIBE-OPAZO, M. A.; NÓBREGA, L. H. P.; PINHEIRO NETO, R. Influência da distância entre passadas de colhedora equipada com monitor de colheita na precisão dos mapas de produtividade na cultura do milho. **Engenharia Agrícola**, Jaboticabal, v. 28, n. 2, p. 355-363, abr./jun. 2008.
- BAZZI, C. L.; SOUZA, E. G. de; RODRIGUES, R.; NÓBREGA, L. H. P.; URIBE-OPAZO, M. A.; SANTOS, D. dos; KONOPATZKI, M. R. S.; SUSZEK, G. Definição de unidades de manejo para controle de plantas invasoras. In: **Avances en Ingeniería Rural 2007-2009**. Rosario: UNR, 2009. p. 835-842.
- BEZDEK, J. C.; CORAY, C.; GUNDERSON, R.; WATSON, J. Detection and Characterization of Cluster Substructure II. Fuzzy c-Varieties and Convex Combinations Thereof. **Journal on Applied Mathematics**, v. 40, n. 2, p. 358-372, 1981.
- BLACKMORE, S. The interpretation of trends from multiple yield maps. **Computers and Electronics in Agriculture**, Orlando, v. 26, n. 1, p. 37-51, mar. 2000.
- BOHÓRQUEZ, I. A.; CEBALLOS, E. V. Algunos Conceptos de la Econometría Espacial y el Análisis Exploratorio de Datos Espaciales. **Ecos de Economía**, Medellín, n. 27, p. 9-34, out. 2008.
- BONHAM C. D.; REICH R. M.; LEADER K. K. Spatial cross-correlation of *Bouteloua gracilis* with site factors. **Grassland Science**, v. 41, n. 3, p. 196-201, 1995.

BOYDELL, B.; MCBRATNEY, A. B. Identifying Potential Within-Field Management Zones from Cotton-Yield Estimates. **Precision Agriculture**, v. 3, n. 1, p. 9-23, 2002.

CANNON, R. L.; DAVE, J. V.; BEZDEK, J. C. Efficient Implementation of the Fuzzy C-means Clustering Algorithms. **IEEE transactions on pattern analysis and machine intelligence**, v. 8, n. 2, 1986.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileira: grãos**, nono levantamento, junho 2011. Brasília: CONAB, 2011. 47 p.

CARVALHO, F. M. V.; FERREIRA, L. G.; LOBO, F. C.; DINIZ FILHO, J. A. F.; BINI, L. M. Padrões de autocorrelação espacial de índices de vegetação MODIS no bioma cerrado. **Revista Árvore**, Viçosa, v. 32, n. 2, p. 279-290, 2008.

COELHO, E. C.; SOUZA, E. G.; 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.

CONGALTON, R. G. A review of assessing the accuracy of classification of remotely sensed data. **Remote Sensing of Environment**, St. Paul, v. 37, n. 1, p. 35-46, 1991.

CORTE, L. M. D. C.; GONSALVES, J. C.; SILVA, C. S.; DUTRA, M. F.; ROCHA, D. B.; URTIZG, C. B.; VALCHER, R. A.; LUCAS, C. A. P.; CORTE, E. A. D.; VARGAS, V. R. A. Análise da concordância interobservadores em exames de Papanicolaou. **News Lab**, v. 80, n. 1, p. 98-106, 2007.

COSTA, J. A. **Cultura da soja**. Porto Alegre: Evangraf, 1996. 233 p.

CRESSIE, N. **Statistics for spatial data**. New York: John Wiley & Sons, 1993. 887 p.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; JOHANN, J. A.; BORSSOI, J. A. Comparison measures of maps generated by geostatistical methods. **Engenharia Agrícola**, Jaboticabal, v. 32, n. 1, p. 174-183, 2012.

DUNN, J. C. A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters. **Cybernetics and Systems**, v. 3, n. 3, p. 32-57, 1973.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. 2. ed. Rio de Janeiro, 2006. 306 p.

EMBRAPA SOJA. **Tecnologias de produção de soja** – região central do Brasil 2009 e 2010. Londrina: Sistemas de Produção / Embrapa Soja, 2008. 262 p.

FERREIRA, D. F. SISVAR: um programa para análises e ensino de estatística. **Revista Symposium**, Lavras, v. 6, p. 36-41, 2008.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185–201, 2002.

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.

FRIDGEN, J. J.; KITCHEN, N. R.; SUDDUTH, K. A. Variability of soil and landscape attributes within sub-field management zones. In: International Conference on Precision

Agriculture, 5., 2000, Bloomington. **Anais...** Bloomington: ASA-CSSA-SSSA, 2000. CD-ROM.

FRIDGEN, J. J.; KITCHEN, N. R.; SUDDUTH, K. A.; DRUMMOND, S. T.; WIEBOLD, W. J.; FRAISSE, C. W. Management zone analyst (MZA): software for subfield management zone delineation. **Agronomy Journal**, Madison, v. 96, n. 1, p. 100-108, 2004.

GOMES, R. P. **A soja**. São Paulo: Nobel, 1976. 149 p.

GOOGLE EARTH. Versão 5.0. Software de imagens, 2009. Disponível em <<http://earth.google.com>>. Ano da imagem: 6 mar. 2010. Acesso em 13 abr. 2011.

GUASTAFERRO, F.; CASTRIGNANO, A.; BENEDETTO, A. de; SOLLITTO, D.; TROCCOLI, A.; CAFARELLI, B. A comparison of different algorithms for the delineation of management zones. **Precision Agriculture**. v. 11, n. 6, p. 600-620, 2010.

JOHANN, J. A.; URIBE-OPAZO, M. A.; SOUZA, E. G. de; ROCHA, J. V. Variabilidade espacial dos atributos físicos do solo e da produtividade em um Latossolo Bruno distrófico da região de Cascavel, PR. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 8, n. 2-3, p. 212-219, 2004.

KALKHAN, M. A.; STAFFORD, E. J.; WOODLY, P. J.; STOHLGREN, T. J. Assessing exotic plant species invasions and associated soil characteristics: A case study in eastern Rocky Mountain National Park, Colorado, USA, using the pixel nested plot design. **Applied Soil Ecology**, v. 35, n. 3, p. 622-634, 2007.

KONOPATZKI, M. R. S.; SOUZA, E. G.; SUSZEK, G.; SANTOS, D.; BAZZI, C. Análise temporal da variabilidade espacial da produtividade em um pomar de peras. In: **Avances en Ingeniería Rural 2007-2009**. 1ª ed. Rosario: UNR, 2009. p. 882-889.

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

LOPES, A.S. **Manual internacional de fertilidade do solo**. Piracicaba: Associação Brasileira para Pesquisa da Potassa do Fosfato, 1995. 177p.

LUDWIG, M. P.; DUTRA, L. M. C.; LUCCA FILHO, O. A.; ZABOT, L.; JAUER, A.; UHRY, D. Populações de plantas na cultura da soja em cultivares convencionais e Roundup ReadyTM. **Revista Ceres**, v. 58, n. 3, p. 305-313, 2011.

MENEGATTI, L. A. A.; MOLIN, J. P. Metodologia para identificação e caracterização de erros em mapas de produtividade. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 7, n. 2, p. 367-374, 2003.

MCBRATNEY, A. B.; MOORE, A. W. Application of fuzzy sets to climatic classification. **Agricultural and Forest Meteorology**, v. 35, n. 1-4, p. 165-185, 1985.

MICROSOFT CORPORATION. **Microsoft Office Excel® 2010** (parte do Microsoft Office Professional Plus 2010), versão 14.0.6112.5000. 2010. 1 DVD-ROM.

MIELKE, P. W. J.; BERRY, K. J. **Permutation methods: a distance function approach**. New York: Springer, 2007. 439 p.

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, out./dez. 2006.

MINASNY, B.; MCBRATNEY, A. B. **FuzME version 3**. Australian Centre for Precision Agriculture, The University of Sydney, 2002. Disponível em <<http://sydney.edu.au/agriculture/acpa/software/fuzme.shtml>>. Acesso em 07 mar. 2011.

MINITAB Inc. **MINITAB® 16 Statistical Software Trial**. State College, Pennsylvania, 2010. Disponível em <<http://www.minitab.com>>. Acesso em 15 jan. 2011.

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

MOLIN, J. P. Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, Jaboticabal, v. 22, n. 1, p. 83-92, 2002.

MOLIN, J. P.; CASTRO, C. N. de C. Establishing management zones using soil electrical conductivity and other soil properties by the fuzzy clustering technique. **Scientia Agrícola**, v. 65, n. 6, p. 567-573, 2008.

MOLIN, J. P.; MASCARIN, L. S. Colheita de citros e obtenção de dados para mapeamento da produtividade. **Engenharia Agrícola**, Jaboticabal, v. 27, n. 1, p. 259-266, jan./abr. 2007.

MOLIN, J. P.; MOTOMIYA, A. V. de A.; FRASSON, F. R.; FAULIN, G. D. C.; TOSTA, W. Test procedure for variable rate fertilizer on coffee. **Acta Scientiarum Agronomy**, Maringá, v. 32, n. 4, p. 569-575, 2010.

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**, v. 6, n. 3, p. 309-324, 2007.

MORARI, F.; CASTRIGNANÒ, A.; PAGLIARIN, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. **Computers and Electronics in Agriculture**, v. 68, n. 1, p. 97-107, 2009.

MOTOMIYA, A. V. A.; MOLIN, J. P.; MOTOMIYA, W. R.; VIEIRA, S. R. Spatial variability of soil properties and cotton yield in the Brazilian Cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 15, n. 10, p. 996-1003, 2011.

ORTIZ, J. L.; VETTORAZZI, C. A.; COUTO, H. T. Z.; GONÇANVES, J. L. M. Relações espaciais entre o potencial produtivo de um povoamento de eucalipto e atributos do solo e do relevo. **Scientia Florestalis**, Piracicaba, v. 1, n. 72, p. 67-79, 2006.

PAIVA, W. L.; KHAN, A. S. Dependência espacial e emprego formal: O que é possível afirmar para indústria cearense? Instituto de Pesquisa e Estratégia Econômica do Ceará. In: Economia do Ceará em Debate, 6., 2010, Fortaleza. **Anais...** Fortaleza: IPECE, 2010.

PIMENTEL GOMES, F. P.; GARCIA, C. H. **Estatística aplicada a experimentos agrônômicos e florestais**. Piracicaba: FEALQ, 2002. 305 p.

PING, J. L.; DOBERMANN, A. Site-Specific Management: Creating Spatially Contiguous Yield Classes for Site-Specific Management. **Agronomy Journal**, v. 95, n. 5, p. 1121-1131, 2003.

PIRES, J. L. F.; COSTA, J. A.; THOMAS, A. L.; MAEHLER, A. R. Efeitos de populações e espaçamentos sobre o potencial de rendimento da soja durante a ontogenia. **Pesquisa Agropecuária Brasileira**, Brasília, v. 35, n. 8, p. 1541-1547, 2000.

RABELO, T. C.; PARRÉ, J. L.; ALVES, A. F. Efeitos espaciais na produção de soja no estado do Paraná. In: Congresso da sociedade brasileira de economia e sociologia rural, 49., 2007,

Londrina. **Anais eletrônicos...** Londrina: UEL, 2007. Disponível em: <<http://www.sober.org.br/palestra/6/171.pdf>>. Acesso em: 12 fev. 2011.

RACHID JUNIOR, A.; URIBE-OPAZO, M. A.; SOUZA, E. G. de; JOHANN, J. A. Variabilidade espacial e temporal de atributos químicos do solo e da produtividade da soja num sistema de agricultura de precisão. **Engenharia na Agricultura**, Viçosa, v. 14, n. 3, p. 156-169, 2006.

RAIJ, B. V. **Fertilidade do solo e adubação**. Piracicaba: Agronômica Ceres, Associação Brasileira para a Pesquisa da Potassa e do Fosfato, 1991. 343p.

REICH, R. M.; CZAPLEWSKI, R. L.; BECHTOLD, W. A. Spatial cross-correlation in growth of undisturbed natural shortleaf pine stands in northern Georgia. **Journal of Environmental and Ecological Statistics**, v. 1, n. 1, p. 201-217, 1994.

RODRIGUES JUNIOR, F. A.; VIEIRA, L. B.; QUEIROZ, D. M. de; 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.

ROUDIER, P.; TISSEYRE, B.; POILVE, H.; ROGER, J. M. A technical opportunity index adapted to zone-specific management. **Precision Agriculture**, v. 12, n. 1, p. 130-145, 2011.

SERRAT, B. M.; LIMA, M. R.; GARCIA, C. E.; FANTIN, E. R.; CARNIERI, I. M. R. S. A.; PINTO, L. S. **Conhecendo o Solo**. Curitiba: UFPR, 2002. 27 p.

SILVA, A. R. da; YAMASHITA, Y. Análise da matriz de proximidades espacial para problemas de transporte. In: Congresso de Pesquisa e Ensino em Transportes, 21, 2007, Rio de Janeiro. **Anais...** Rio de Janeiro: ANPET, 2007.

SILVA, C. B.; MORAES, M. A. F. D. de; MOLIN, J. P. Adoption and use of precision agriculture technologies in the sugarcane industry of São Paulo state, Brazil. **Precision Agriculture**, v. 12, n. 1, p. 67-81, 2011.

SILVA, C. B.; MORETTO, A. C.; RODRIGUES, R. L. Viabilidade econômica da agricultura de precisão: O caso do Paraná. In: Congresso da SOBER, 42, 2004, Cuiabá. **Anais eletrônicos...** Cuiabá: SOBER, 2004. Disponível em: <<http://www.sober.org.br/palestra/12/12O499.pdf>>. Acesso em: 21 fev. 2011.

STAFFORD, J. V., AMBLER, B.; LARK, R. M.; CATT, J. Mapping and interpreting yield variation in cereal crops. **Computers and Electronics in Agriculture**. Amsterdam, v. 14, n. 2, p. 101-119, 1996.

SUSZEK, G.; SOUZA, E. G. de; URIBE-OPAZO, M. A.; NOBREGA, L. H. P. Unidades de manejo a partir de mapas de produtividade normalizada e padronizada equivalente. **Engenharia Agrícola**, v. 31, n. 5, p. 895-905, 2011.

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**, Amsterdam, v. 84, n. 4, p. 441-453, abr. 2003.

TOBLER, W. R. Cellular geography. In: GALE, S.; OLSSON, G. (Ed.). **Philosophy in geography**. Dordrecht: D. Reidel Pub. Co., 1979, p.379-386.

VIEIRA, S. R.; DECHEN, S. C. F.; SIQUEIRA, G. M.; DUFRANC, G. Variabilidade espacial de atributos físicos e químicos relacionados com o estado de agregação de dois Latossolos cultivados no sistema de semeadura direta. **Bragantia**, Campinas, v. 70, n. 1, p. 185-195, 2011.

VITHARANA, U. W. A.; MEIRVENNE, M. V.; SIMPSON, D.; COCKX, L.; BAERDEMAEKER, J. de. Key soil and topographic properties to delineate potential management classes for precision agriculture in the European loess area. **Geoderma**, v. 143, n. 1-2, p. 206-215, 2008.

WINDHAM, M. P. Cluster validity C-means for fuzzy clustering algorithm. **IEEE Transactions. Pattern Analyses Machine Intelligence**, New York, v. 4, n. 4, p. 354-363, 1982.

XIANG, L.; YU-CHUN, P.; ZHONG-QIANG, G.; CHUN-JIANG, Z. Delineation and Scale Effect of Precision Agriculture Management Zones Using Yield Monitor Data Over Four Years. **Agricultural Sciences In China**, Maryland, v. 6, n. 2, p. 180-188, fev. 2007.

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

ANEXOS

ANEXO A – Boxplots da produtividade dentro das classes de UM




Figura 12 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 02-CuSiAl com 2, 3, 4 e 5 classes.




Figura 13 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 03-CuSi com 2, 3, 4 e 5 classes.




Figura 14 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 04-Cu com 2, 3, 4 e 5 classes.




Figura 15 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 05-CuSiAr com 2, 3, 4 e 5 classes.




Figura 16 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 06-CuAlAr com 2, 3, 4 e 5 classes.




Figura 17 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 07-SiAlAr com 2, 3, 4 e 5 classes.




Figura 18 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 08-CuAl com 2, 3, 4 e 5 classes.




Figura 19 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 09-CuAr com 2, 3, 4 e 5 classes.




Figura 20 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 10-SiAl com 2, 3, 4 e 5 classes.




Figura 21 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 11-SiAr com 2, 3, 4 e 5 classes.




Figura 22 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 12-ArAl com 2, 3, 4 e 5 classes.




Figura 23 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 13-Si com 2, 3, 4 e 5 classes.




Figura 24 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 14-AI com 2, 3, 4 e 5 classes.




Figura 25 Boxplot da produtividade dentro de cada classe do delineamento em unidades de manejo 15-Ar com 2, 3, 4 e 5 classes.