

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

**IDENTIFICAÇÃO DE ZONAS DE MANEJO COM A EXPERIÊNCIA DO
PRODUTOR**

KELYN SCHENATTO

CASCAVEL, PR

2017

KELYN SCHENATTO

**IDENTIFICAÇÃO DE ZONAS DE MANEJO COM A EXPERIÊNCIA DO
PRODUTOR**

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

Orientador: Prof. Dr. Eduardo Godoy de Souza

CASCADEL, PR

2017

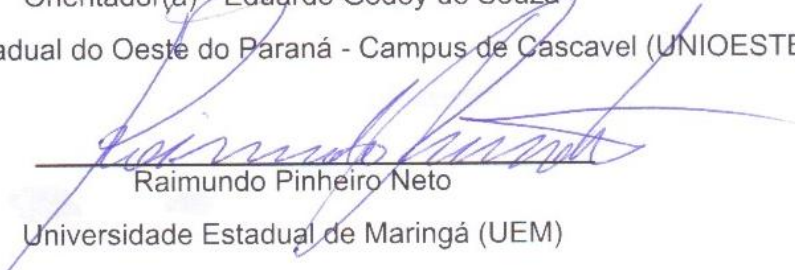
KELYN SCHENATTO

Identificação de Zonas de Manejo com a Experiência do Produtor

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutora em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:


Orientador(a) - Eduardo Godoy de Souza

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Raimundo Pinheiro Neto

Universidade Estadual de Maringá (UEM)


Antônio Carlos Andrade Gonçalves

Universidade Estadual de Maringá (UEM)


Marcio Furlan Maggi

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 16 de fevereiro de 2017

BIOGRAFIA

Kelyn Schenatto nasceu em 14 de fevereiro de 1991 na cidade de Medianeira – PR. No ano de 2011 concluiu o curso de Tecnologia em Análise e Desenvolvimento de Sistemas pela Universidade Tecnológica Federal do Paraná (UTFPR – Campus Medianeira). Em 2012 ingressou no curso de Pós-Graduação em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, nível mestrado, na Universidade Estadual do Oeste do Paraná (UNIOESTE) sob orientação do professor Dr. Eduardo Godoy de Souza. Em 2014 concluiu o mestrado com a dissertação intitulada “Utilização de Métodos de Interpolação e Agrupamento para Definição de Unidades de Manejo em Agricultura de Precisão”. Em 2014 concluiu a especialização em Engenharia de Software na UTFPR – Medianeira. Em fevereiro de 2014, ingressou no curso de Doutorado em Engenharia Agrícola – área de concentração Sistemas Biológicos e Agroindustriais – na Universidade Estadual do Oeste do Paraná (UNIOESTE), também sob orientação do professor Dr. Eduardo Godoy de Souza. Atualmente, é professora efetiva na Universidade Tecnológica Federal do Paraná (UTFPR), campus Santa Helena, atuando como professora do ensino superior do Departamento de Computação.

Quem deseja ver o arco-íris, precisa aprender a gostar da chuva.

Paulo Coelho

Dedico este trabalho aos meus pais, Wanderlei e Marisete, e ao meu esposo, Claudio, que de muitas formas me incentivaram e auxiliaram para que fosse possível a concretização desta nova etapa da minha vida.

AGRADECIMENTOS

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

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

Ao meu orientador na Universidade da Califórnia, Professor SHRINI K. UPADHYAYA pela acolhida, o apoio e o auxílio prestados durante o tempo que estive nessa Universidade;

À UNIOESTE, em especial ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade de crescimento profissional e pessoal;

À Universidade Tecnológica Federal do Paraná (UTFPR – campus Santa Helena) e a todos os colegas do curso de Ciência da Computação, pelo apoio durante a realização do doutorado. Esse suporte foi fundamental para que eu pudesse desenvolver este trabalho com maior dedicação;

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

A todos os amigos e colegas de laboratório que de alguma forma contribuíram no desenvolvimento desta pesquisa, em especial, ALAN, HUMBERTO, NELSON e VANDERLEI pelo apoio e a colaboração, principalmente nas atividades de campo;

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

De forma especial, ao meu esposo CLAUDIO, pelo amor, pelo carinho e por estar sempre me apoiando ao longo dessa caminhada;

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

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

IDENTIFICAÇÃO DE ZONAS DE MANEJO COM A EXPERIÊNCIA DO PRODUTOR

RESUMO

O processo de geração de zonas de manejo (ZMs) compreende várias etapas, entre elas a escolha das variáveis a serem utilizadas no processo de agrupamento, a escolha do melhor interpolador, o uso de um método de normalização de dados e a escolha de um algoritmo adequado para o processo de agrupamento, além de índices de avaliação adequados. Neste trabalho, buscou-se melhorar técnicas utilizadas no processo de geração de ZMs e, para isso, primeiro foi estudada a influência de técnicas de normalização de dados no processo de agrupamento utilizando o algoritmo Fuzzy C-Means, em que foram avaliadas as três principais técnicas de normalização de dados propostas na literatura. Avaliou-se também a utilização da experiência do produtor como uma nova variável para a geração das ZMs, e foi desenvolvido um software para fins de definição dessa variável e para gerenciamento de dados agrícolas. Os experimentos foram realizados com dados obtidos entre os anos de 2011 e 2016 de quatro áreas agrícolas comerciais, localizadas no estado do Paraná, nas quais se cultivaram milho e soja. Com os experimentos realizados foi possível concluir que a técnica de normalização de dados exerce influência no processo de agrupamento quando é utilizada mais de uma variável com diferentes escalas de valores e que a técnica que apresentou melhores resultados foi a de normalização pela amplitude dos dados. A variável proposta "experiência do produtor" apresentou bons resultados na geração das ZMs. Fazendo uso dessa variável foi possível gerar zonas de manejo com potencial produtivo distinto entre as classes e, sendo assim, pode ser utilizada como uma nova variável a ser utilizada juntamente com as variáveis estáveis do solo. Com base nos bons resultados obtidos pela variável experiência do produtor em três áreas agrícolas, foi desenvolvido um software que permite a inserção dessa variável pelo produtor. O software chamado AgData-Mobile permite, ainda, realizar o gerenciamento de dados de campo, possibilitando que o produtor insira dados de todas as operações realizadas em cada talhão e mantenha um registro de suas áreas. Além disso, tal ferramenta se destaca por ser de uso gratuito e pelo armazenamento de dados em nuvem.

Palavras-chave: unidades de manejo; agricultura de precisão; agrupamento; percepção do produtor.

IDENTIFICATION OF MANAGEMENT AREAS USING THE FARMER'S EXPERIENCE

ABSTRACT

The process of generating management zones (MZs) comprises several steps, among them the choice of variables to be used in the grouping process, the choice of the best interpolator, the use of a data normalization method and the choice of an algorithm suitable for the grouping process, as well as adequate evaluation indices. In this work, it was attempted to improve techniques used in the MZs generation process. First, the influence of data normalization techniques in the clustering process was studied using the Fuzzy C-Means algorithm data proposed in the literature. It was also evaluated the use of the producer's experience as a new variable for the generation of the MZs and a piece of software was developed for the purpose of capturing this variable and managing agricultural data. The experiments were carried out with data obtained between the years of 2011 and 2016 from four commercial agricultural areas, located in the State of Paraná, where corn and soybean had been grown. With the experiments concluded, it was possible to assert that the technique of normalization of data influences the process of grouping when more than one variable is used with different scales of values and that the technique that presented better results was the normalization by amplitude. The proposed variable "farmer's experience" showed good results in the generation of the MZs and, with such, it was possible to generate management areas with different productive potential between the classes and thus, it can be used as a new variable to be used combined with the variables of stable soil conditions. Based on the positive results generated by the variable experience of the producer in three agricultural areas, a piece of software was developed that allows the insertion of this variable by the producer. The software called AgData-Mobile also allows the management of field data, allowing the producer to insert data of all the operations performed in each field and to keep a record of their areas. In addition this tool stands out for being free and for using cloud storage.

Keywords: management units; precision agriculture; clustering; farmer feeling.

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	Organização da tese.....	2
2	OBJETIVOS.....	4
2.1	Objetivo geral.....	4
2.2	Objetivos específicos.....	4
3	REVISÃO BIBLIOGRÁFICA.....	5
3.1	Atributos do solo.....	5
3.2	Variabilidade espacial dos atributos do solo e produtividade.....	6
3.3	Agricultura de precisão.....	7
3.4	Análise geostatística e geração de mapas temáticos.....	8
3.5	Zonas de manejo.....	8
3.6	Experiência do produtor.....	9
3.7	Métodos para geração de zonas de manejo.....	10
3.8	Avaliação de zonas de manejo.....	11
3.9	Desenvolvimento de software para agricultura.....	12
3.10	Análise e desenvolvimento de software para dispositivos móveis.....	13
4	REFERÊNCIAS.....	15
5	ARTIGO 1 – IMPORTÂNCIA DA NORMALIZAÇÃO DE DADOS PARA DEFINIÇÃO DE ZONAS DE MANEJO.....	21
5.1	Introdução.....	22
5.2	Material e métodos.....	23
5.3	Resultados e discussão.....	30
5.4	Conclusões.....	37
5.5	Referências.....	38
6	ARTIGO 2 – UTILIZAÇÃO DA VARIÁVEL EXPRIÊNCIA DO PRODUTOR NA GERAÇÃO DE ZONAS DE MANEJO.....	42
6.1	Introdução.....	43
6.2	Material e métodos.....	44
6.3	Resultados e discussão.....	48
6.4	Conclusões.....	58
6.5	Referências.....	59
7	ARTIGO 3 – SOFTWARE PARA CONTROLE DE INFORMAÇÕES DE CAMPO E DEFINIÇÃO DA VARIÁVEL EXPERIÊNCIA DO PRODUTOR PARA GERAÇÃO DE ZONAS DE MANEJO.....	62
7.1	Introdução.....	63
7.2	Material e métodos.....	64

7.2.1	Tecnologias de análise e desenvolvimento do software AgData-Mobile.....	64
7.2.2	Estudo de caso.....	66
7.3	Resultados e discussão.....	73
7.3.1	Aplicativo AgData-Mobile.....	73
7.3.2	Experiência do produtor na geração de ZMs.....	78
7.4	Conclusões.....	79
7.5	Referências.....	79
8	CONSIDERAÇÕES FINAIS.....	83
8.1	Conclusões.....	83
8.2	Trabalhos futuros.....	84
	APÊNDICES.....	85
	APÊNDICE A – TUTORIAL E DESCRIÇÃO DO SOFTWARE AGDATA-MOBILE...	86

LISTA DE TABELAS

ARTIGO 1

Tabela 1	Identificação dos tipos de atributos e períodos de coleta para cada área experimental.....	25
Tabela 2	Esquema de seleção e eliminação de variáveis (atributos) para geração de zona de manejo.....	31
Tabela 3	Análise geoestatística das variáveis selecionadas para geração das ZMs.....	32
Tabela 4	Índices de avaliação calculados para diferentes métodos de normalização em cada área.....	35

ARTIGO 2

Tabela 1	Esquema de seleção e eliminação de variáveis (atributos) para definição de zonas de manejo.....	49
Tabela 2	Índices de avaliação calculados considerando a geração de ZMs sem a adição da variável experiência do produtor (somente com atributos estáveis selecionados na matriz de correlação), com variável experiência do produtor e atributos estáveis do solo selecionados na matriz de correlação e somente com a variável experiência do produtor.....	54
Tabela 3	Anova para os atributos do solo nas áreas A, B e C em relação às ZMs geradas com duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor.....	58

ARTIGO 3

Tabela 1	Bibliotecas Android utilizadas para o desenvolvimento do aplicativo AgData-Mobile.....	65
Tabela 2	Variáveis coletadas na área experimental em cada ano de estudo.....	67
Tabela 3	Porcentagem da variância total dos dados representada pela SPC e somatório das porcentagens correspondentes às SPCs...	69
Tabela 4	Estatísticas de avaliação das zonas de manejo geradas (ZMs)...	79

LISTA DE FIGURAS

ARTIGO 1

Figura 1	Áreas experimentais e pontos amostrais.....	24
Figura 2	Representação da diferença que ocorre no cálculo da distância euclidiana quando utilizadas diferentes unidades de medida.....	28
Figura 3	Zonas de manejo para a área A, geradas com o atributos altitude (m) e RSP 0-0,1 m (MPa) (2013), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude(c) e média (d).....	32
Figura 4	Zonas de manejo para a área B, geradas com os atributos altitude (m) e RSP 0-0,1 m (MPa) (2012), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).....	33
Figura 5	Zonas de manejo para a área C, geradas com o atributo altitude (m), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).....	33
Figura 6	Zonas de manejo para a área B, geradas com os atributos altitude (m) e RSP 0-0,1 m (kPa) (2012), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).....	34
Figura 7	Estatísticas de VR(%); FPI e MPE obtidas na clusterização das áreas A, B e C.....	36
Figura 8	Índice de suavidade calculados para as áreas A, B e C, em função dos métodos de normalização.....	36
Figura 9	Gráficos do índice Kappa de comparação das ZMs. N.N – Não normalizado; S.S. Método de normalização escore padrão.....	37

ARTIGO 2

Figura 1	Áreas experimentais: Área A: Céu Azul, Paraná, Brasil; Área B: Serranópolis do Iguaçu, Paraná, Brasil; Área C: Cascavel, Paraná, Brasil.....	45
Figura 2	Mapas temáticos dos atributos do solo (elevação e RSP 0-0,1) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área A e as zonas de manejo geradas sem a variável experiência do produtor(SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE).....	50
Figura 3	Mapas temáticos dos atributos do solo (elevação) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área A e as zonas de manejo geradas sem a variável experiência do produtor (SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE).....	51
Figura 4	Mapas temáticos dos atributos do solo (elevação) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área C e as zonas de manejo geradas sem a variável experiência do produtor (SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE).....	52

Figura 5	Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para a área A.....	55
Figura 6	Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para a área B.....	55
Figura 7	Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para area C.....	56
Figura 8	Gráficos do índices FPI, MPE, VR% e IS para as três abordagens avaliadas, considerando dois, três e quatro classes.....	57
ARTIGO 3		
Figura 1	Fluxograma de funcionamento do aplicativo AgData-Mobile.....	66
Figura 2	Delimitação da área amostral.....	67
Figura 3	Mapas de produtividade dos quatro anos agrícolas (2012, 2013, 2014 e 2015) e produtividade média normalizada interpolados por krigagem ordinária.....	68
Figura 4	Fluxograma de representação do processo de geração das ZMs.....	72
Figura 5	Telas de cadastro, login e menu inicial do software ADF Mobile (AgData-Mobile).....	73
Figura 6	Representação do processo de cadastro de área no aplicativo AgData-Mobile;,,,,;.....	74
Figura 7	Registro de safra e da operação de plantio.....	75
Figura 8	Registro de operação de pulverização.....	76
Figura 9	Processo de definição da experiência do produtor.....	77
Figura 10	Variável experiência do produtor obtida por meio do AgData-Mobile.....	78
Figura 11	Mapas temáticos das variáveis do solo RSP 0,0-0,1 m, altitude, areia e argila.....	78
Figura 12	Zonas de manejo geradas utilizando as variáveis SPC1 e SPC2.....	79

1 INTRODUÇÃO

O crescimento da população mundial implica no aumento da demanda por alimentos e uma conseqüente pressão para expansão das áreas agrícolas. Porém, a expansão da agricultura nos ecossistemas naturais afeta a biodiversidade e conduz ao aumento da emissão de gases como o dióxido de carbono. Devido a isso, segundo Wirsenius, Azar e Berndes (2010), uma considerável atenção tem sido dada à perspectiva de aumentar a disponibilidade de alimentos, limitando a expansão agrícola, por meio de rendimentos mais elevados nas áreas cultivadas.

Além do aumento na produção alimentícia, existem os problemas com o aumento das emissões de gases que causam o efeito estufa, o qual, para Ajanovic (2010), devem ser minimizados pela substituição de combustíveis fósseis pelos biocombustíveis provenientes de matérias-primas como milho, trigo, cana-de-açúcar, soja, canola e girassol. O principal problema é que estas matérias-primas são também utilizadas para a alimentação humana e animal.

Assim, para que seja possível aumentar a produção agrícola com menor expansão das áreas produtoras, há necessidade de desenvolvimento de pesquisas visando, entre outras coisas, o melhor manejo do solo e das plantas, potencializado pela utilização de técnicas de agricultura de precisão (AP), apoiada pela utilização de máquinas e equipamentos que permitem o gerenciamento localizado da lavoura.

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

A AP evoluiu muito nas últimas décadas, sendo que sua adoção está se tornando fundamental para a viabilidade econômica da atividade agrícola. Em contrapartida, produtores de menor porte e com menor capacidade financeira acabam sendo prejudicados pela falta de recursos e incentivos para aquisição dos maquinários e dispositivos necessários. O delineamento de zonas de manejo (ZMs) tem sido uma alternativa para proporcionar uma solução econômica para este problema, funcionando como unidade de operação para aplicação localizada de insumos e como indicador para amostragem do solo e da cultura (SCHEPERS et al., 2004; MILANI et al., 2006; ORTEGA; SANTIBÁÑEZ, 2007).

Na definição de ZMs utilizam-se usualmente dados de produtividade, dados físicos e químicos do solo, condutividade elétrica, dados topográficos e a combinação entre eles (HORNUNG et al., 2006; FLEMING et al., 2004; KHOSLA et al., 2002), sendo os métodos de agrupamento tais como algoritmos K-Means (FRIDGEN et al., 2004; RODRIGUES

JUNIOR et al., 2011) e Fuzzy C-Means (FRAISSE et al., 2001; BOYDELL; MACBRATNEY, 2002; DOBERMANN et al., 2003; LI et al., 2007), sendo estes os mais utilizados.

Para Ortega e Santibáñez (2007), mais importante do que o método de definição das ZMs é a etapa de seleção de quais variáveis (*layers*) irão ser utilizadas para realizar os agrupamentos de dados que representarão cada sub-região do talhão. Neste sentido, Doerge (2000) sugere a utilização de dados estáveis, já que após a definição das ZMs é ideal que estas sejam consideradas por uma sequência de anos.

Os produtores sabem quais áreas de um talhão apresentam grandes rendimentos e quais áreas que são de baixa produtividade e, segundo Fleming e Westfall (2000), fazer uso dessa base de conhecimento pode permitir a identificação de diferentes zonas de manejo com base no histórico de produção. Vários autores como Hörbe et al. (2013), Fleming et al. (2014) e Khosla et al. (2002) definiram ZMs utilizando a experiência do produtor e encontraram bons resultados, além de similaridade entre os mapas de análises de solo e os gerados com a experiência do produtor na área.

Apesar da importância de se considerar o conhecimento empírico do produtor para a definição das possíveis restrições à produtividade das culturas, a dificuldade no levantamento deste tipo de dados corresponde a um dos possíveis impedimentos para sua utilização, já que o ideal é que o produtor realize a campo o registro de sua percepção. É inegável que se deve realizar a utilização de recursos computacionais, tais como softwares especialistas e dispositivos eletrônicos, os quais permitem, por meio de técnicas de engenharia agrícola, agronômicas ou conhecimento empírico, determinar áreas para correção localizada de forma fácil e eficiente, permitindo que o produtor possa gerenciar a lavoura de maneira eficiente e com baixo custo.

1.1 Organização da tese

Esta tese está disposta na forma de artigos científicos. Em razão disso, inicialmente apresenta-se no Capítulo 3 uma revisão teórica geral, com o propósito de servir de fundamentação teórica abrangente para os três artigos que compõem o trabalho. No Capítulo 4 apresenta-se o primeiro artigo elaborado como parte do projeto de doutorado. Nesse artigo, avalia-se o desempenho de três diferentes técnicas de normalização de variáveis no processo de geração de ZMs. No Capítulo 5 apresenta-se o segundo artigo, no qual se avaliou a eficácia da utilização da variável experiência do produtor na geração de ZMs. O Capítulo 6 corresponde ao terceiro artigo, que teve o objetivo de apresentar um software para dispositivos móveis aplicado no registro e no gerenciamento das informações de operações de campo e na definição da variável experiência do produtor para geração de ZMs, com um estudo de caso para validação da utilização dessa variável no processo de

geração de ZMs. Por fim, no Capítulo 7 apresentam-se as conclusões gerais do trabalho desenvolvido e algumas atividades a serem realizadas como trabalhos futuros. Como apêndice desse trabalho também é apresentado um manual de utilização do software desenvolvido.

2 OBJETIVOS

2.1 Objetivo geral

Desenvolver um software aplicativo para ser utilizado em dispositivos móveis que permita ao produtor delimitar a variável “experiência do produtor” e avaliar a utilidade desta informação no processo de geração de zonas de manejo.

2.2 Objetivos específicos

- Avaliar a utilização de três métodos de normalização de dados no processo de geração de ZMs;
- Avaliar a eficiência de utilização da experiência do produtor no processo de geração de ZMs;
- Desenvolver um software aplicativo para dispositivos móveis que permita o mapeamento, em campo, de restrições à produtividade, considerando a experiência do produtor na área;
- Implementar funcionalidades no software que permitam ao produtor inserir dados históricos da área e dados sobre os anos agrícolas (safras).

3 REVISÃO BIBLIOGRÁFICA

3.1 Atributos do solo

A produtividade de uma área agrícola é influenciada, dentre outros fatores, pelos atributos físicos e químicos do solo (GUEDES et al., 2012; LIMA, 2010). Os atributos físicos referem-se às condições do solo que permitem a infiltração, a retenção e a disponibilização de água às plantas (REICHERT et al., 2003). Tais atributos estão ligadas à estrutura e à estabilidade do solo (CARVALHO et al., 2012).

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

A compactação do solo refere-se ao aumento da densidade, como resultado da redução do seu volume; esta resulta na expulsão de ar dos poros e, por conseguinte, um rearranjo das partículas, reduzindo a porosidade e aumentando a densidade (RALISCH et al., 2008). A compactação do solo consiste em um problema que influencia diretamente o desenvolvimento das culturas, sendo que, para Queiroz-Voltan, Nogueira e Miranda (2000), as raízes das plantas não se beneficiam adequadamente dos nutrientes disponíveis em solos compactados, uma vez que o desenvolvimento de novas raízes, responsável pela absorção de água e nutrientes, fica prejudicado.

A classe textural do solo está relacionada com a proporção de tamanho das suas partículas minerais (KLEIN et al., 2010). Esta pode ser analisada por meio da análise granulométrica, que permite classificar em areia, silte e argila, os componentes sólidos, de acordo com o seu diâmetro. A textura constitui-se em uma das características mais estáveis do solo (VIEIRA et al., 2007), sendo sua variabilidade decorrente da variação natural do mesmo (OLIVEIRA JÚNIOR et al., 2010). Isso faz com que a textura seja considerada um elemento de grande importância na tomada de decisão, na identificação e na classificação do solo (EGUCHI et al., 2002).

O solo apresenta um alto número de elementos químicos, sendo que um elemento é considerado essencial quando ele participa de algum composto ou reação e sem o qual a planta não completa seu ciclo de vida (MALAVOLTA et al., 1997). Os elementos químicos essenciais, também chamados de nutrientes, são classificados em função da quantidade que são absorvidos pelas plantas em dois grupos: os macronutrientes e os micronutrientes.

Os macronutrientes são os que as plantas necessitam em maior quantidade: Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg) e Enxofre (S); e os micronutrientes: Boro (B), Cloro (Cl), Cobre (Cu), Ferro (Fe), Manganês (Mn), Molibdênio (Mo) e o Zinco (Zn), que são exigidos em menor quantidade pelas plantas (LIMA, 2010).

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

A matéria orgânica é originária das plantas, minerais e microorganismos que habitam o solo. Segundo Figueiredo et al. (2008), a importância da matéria orgânica no solo é abrangente. Sua atuação se dá tanto na melhoria das condições físicas, como na aeração, na maior retenção e no armazenamento de água, quanto nas propriedades físico-químicas, no fornecimento de nutrientes às plantas e na maior capacidade de troca catiônica do solo, além de proporcionar um ambiente adequado ao estabelecimento e à atividade da microbiota.

3.2 Variabilidade espacial dos atributos do solo e produtividade

Segundo Wang e Shao (2013), a variabilidade espacial das propriedades do solo é inerente à natureza devido a fatores geológicos e pedológicos. Para Corá et al. (2004), além desses fatores referentes aos processos de formação dos solos, práticas de manejo do solo e da cultura são causas adicionais de variabilidade. Áreas pedologicamente idênticas podem apresentar variabilidade distinta em relação a seus atributos, quando submetidas às diferentes práticas de manejo. O manejo pode alterar a variabilidade dos atributos químicos, físicos, mineralógicos e biológicos, com impacto principalmente nas camadas superficiais do solo.

Xin-Zhong et al. (2009) afirmam que os efeitos dos fatores naturais e o manejo do solo são os responsáveis pela sua variabilidade espacial e estes operam simultaneamente com diferentes intensidades e em diferentes escalas. Devido a isso, a gestão uniforme do talhão possivelmente resulta em áreas com altas concentrações de nutrientes devido ao excesso de tratamento e áreas com níveis baixos de nutrientes, decorrentes do subtratamento.

Em consequência da variabilidade espacial dos solos, a gestão uniforme das lavouras não é considerada a estratégia mais eficaz (XIN-ZHONG et al., 2009) e nem sempre permite resolver adequadamente o gerenciamento do solo (CASA; CASTRIGNANÒ, 2008).

A maneira mais fácil e rápida de obter informações sobre a variabilidade espacial de um campo é por meio do mapeamento de sua produtividade. Segundo Casa e Castrignanò

(2008), a variação espacial final da produtividade das culturas é o resultado da interação entre os elementos influentes no desenvolvimento das plantas.

Para Lima et al. (2008), a análise dos dados por meio dos mapas temáticos dos atributos químicos possibilita a distinção de regiões com menor e maior variabilidade desses atributos, o que permite manejá-los de forma diferenciada e localizada.

3.3 Agricultura de precisão

A Agricultura de Precisão (AP) foi idealizada por agricultores americanos no início da década de 1990 e consiste em um moderno sistema de produção agrícola que aplica ferramentas e tecnologias como Sistema de Posicionamento Global (GPS), Sistema de Informação Geográfica (SIG), sensoriamento remoto, entre outros, para melhorar o processo de tomada de decisão na produção agrícola (FU et al., 2010; MORAL et al., 2011; ORTEGA; SANTIBÁÑEZ, 2007). A AP destina-se a melhorar a produção agrícola por meio da entrada de nutrientes correspondentes às condições de cada local do talhão, no intuito de obter ganhos de eficiência e produtividade, além de menor impacto ambiental (HEDLEY, 2015).

A identificação das condições de campo específicas de cada local do talhão requer medição e compreensão da variabilidade espacial do solo e do estado nutricional das culturas e sua relação com a resposta da cultura (HEDLEY, 2015), o que gera elevados custos com a compra de máquinas agrícolas e as análises de solo para determinação da variabilidade espacial das lavouras.

Segundo Hedley (2015), mesmo com os altos custos e o fato de que a AP possa não trazer grandes retornos financeiros de imediato, ela proporciona a oportunidade de converter o capital, ou seja, as despesas, que antes eram geradas por aplicações incorretas de nutrientes e fertilizantes no solo, em novas tecnologias e métodos de gestão para ganhos de produtividade e retorno financeiro. Além disso, a AP está em consonância com os princípios da agricultura sustentável, evitando o excesso de fertilização e, portanto, diminuindo os riscos ambientais (PORTZ et al., 2012).

Porém, a AP usualmente é economicamente pouco viável para os pequenos produtores (BAZZI et al., 2013; FERRAZ et al., 2011). Além disso, outro fator que eleva o custo de implantação da AP para esses produtores é a necessidade de utilização de uma grade amostral densa na detecção da variabilidade espacial dos atributos do solo.

3.4 Análise geostatística e geração de mapas temáticos

Os atributos do solo são avaliados por meio de processos de amostragem, havendo necessidade de se gerar uma superfície contínua, expressa em um mapa (JOHANN et al., 2004). Tais mapas são gerados por meio de um processo de interpolação que objetiva aumentar a densidade dos dados pontuais. Entre os métodos de interpolação, o mais difundido é a Krigagem, que utiliza a geoestatística para realizar a interpolação, fato que para Alves e Vecchia (2011) o torna vantajoso sobre outros métodos. Esse método utiliza a dependência espacial entre as amostras para estimar valores em qualquer posição dentro do talhão (CARVALHO; ASSAD, 2005).

A principal ferramenta em geoestatística é o semivariograma, que permite determinar o grau de dependência espacial entre as observações vizinhas, considerando que valores obtidos em pontos amostrais mais próximos tendem a possuir maior similaridade do que valores obtidos em pontos mais distantes. O semivariograma experimental pode assumir diversas formas em função dos dados e do intervalo de amostragem. Por esse motivo, Isaaks e Srivastava (1989) afirmam que é necessário ajustar uma função para esses valores. Segundo Cressie (1993), o modelo a ser selecionado deve representar da melhor forma a distribuição das semivariâncias. Por isso, podem ser ajustados modelos distintos, sendo os principais os modelos esférico, exponencial e gaussiano.

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

3.5 Zonas de manejo

Zonas de Manejo (ZMs) podem ser definidas como sub-regiões dentro de um talhão que apresentam topografia e condições do solo espacialmente homogêneas (FLEMING et al., 2004; MORAL et al., 2011; XIN-ZHONG et al., 2009), de tal forma que tais ZMs devem conduzir aos mesmos resultados em potencial de rendimento das culturas, permitindo uma taxa de entrada de nutrientes única em cada sub-região (SCHEPERS, 2004; MILNE et al., 2012; DIACONO et al., 2012).

Também se pode utilizar as ZMs para direcionar projetos de amostragem de solo, reduzindo, então, o número de análises de solo necessárias para desenvolvimento dos mapas de aplicação de nutrientes e fertilizantes, além da variação de determinadas operações de plantio e manejo (LI et al., 2007). Tal metodologia permite ainda que sejam

utilizados os mesmos equipamentos da agricultura convencional, já que a aplicação é variável somente entre zonas. Dessa forma, a definição de ZMs tem sido proposta como uma abordagem de baixo custo para melhorar a gestão das culturas, a qual irá fornecer uma ampla gama de benefícios (econômico, ambiental e social), mas sem necessariamente investir em novas tecnologias na propriedade (XIN-ZHONG, 2009).

Vários pesquisadores que empregaram ZMs obtiveram resultados satisfatórios com diferentes culturas e considerando diferentes atributos para sua delimitação. Tagarakis et al. (2013) trabalhou com a cultura da uva e as variáveis condutividade elétrica, altitude, declividade, profundidade do solo e NDVI, e sua pesquisa resultou em zonas de manejo uniformes para os dois anos avaliados. Li et al. (2007) delinearam ZMs para cultura do algodão, utilizando as variáveis NDVI, condutividade elétrica do solo, nitrogênio total, matéria orgânica e capacidade de troca catiônica (CTC) e chegaram ao número ideal de três classes de manejo. Rodrigues Junior et al. (2011) trabalharam com a cultura do café, as concentrações de nutrientes foliares e dados de clorofila provenientes do sensor SPAD. Bazzi et al. (2013) definiram ZMs para a cultura da soja utilizando os atributos químicos que mais se correlacionaram com a produtividade, chegando ao número ideal de duas ZMs.

3.6 Experiência do produtor

Os cientistas consideram que as experiências dos agricultores foram importantes no desenvolvimento da agricultura como a conhecemos hoje (CROOKSTON, 1996). Para Fleming et al. (2004), se não fosse a experiência de tomada de decisão dos agricultores, grande parte da agricultura moderna seria desconhecida.

Os produtores sabem quais áreas de um talhão apresentam grandes rendimentos e quais áreas que são de baixa produtividade e que as necessidades nutricionais são diferentes entre essas áreas. Fazer uso dessa base de conhecimento pode permitir a identificação de diferentes zonas de gestão em um campo com base no histórico de produção (FLEMING; WESTFALL, 2000).

Para Morari et al. (2009), várias ferramentas podem ser utilizadas na obtenção de dados para geração de ZMs e uma delas é a delimitação visual com base no conhecimento da área por parte do agricultor. Segundo Fleming et al. (2004), infelizmente, as contribuições potenciais do conhecimento do agricultor não estão sendo totalmente utilizadas hoje.

Baseados no conceito de que o produtor tem um rico conhecimento de sua propriedade, vários pesquisadores encontraram bons resultados em trabalhos baseados na experiência do produtor, também tratada como “feeling do produtor”. Hörbe et al. (2013) delineou ZMs com base no conhecimento do agricultor na produtividade da cultura e classificou uma área agrícola em zonas de alta, média e baixa performance na produtividade

da cultura do milho, chegando ao número ideal de três ZMs; a análise de variância indicou heterogeneidade da fertilidade do solo entre as ZMs. Nkoka et al. (2014) implantou sistemas de irrigação em Moçambique que operam de acordo com o contexto específico de cada área e cada sistema exibe um padrão único de gestão, baseados no histórico que o agricultor tem da área. Fleming et al. (2004) comparou mapas de prescrição desenvolvidos a partir da experiência do produtor com mapas de prescrição desenvolvidos a partir de análises da fertilidade do solo, em duas áreas de milho no estado do Colorado-EUA, e os resultados da análise de variância foram semelhantes ao comparar os dois métodos.

3.7 Métodos para geração de zonas de manejo

Na literatura, há diversos métodos propostos para a geração de ZMs (HORNUNG et al., 2006). Li et al. (2007) os dividiram com base em duas abordagens: métodos empíricos e métodos de análise de agrupamento. A abordagem empírica é mais simples e está sujeita a decisões subjetivas. Essa técnica utiliza a distribuição da produtividade e do conhecimento especializado para dividir o talhão em duas ou mais partes (FRAISSE et al., 2001).

A segunda abordagem corresponde aos métodos de agrupamento, que são considerados mais complexos e permitem um maior grau de diferenciação entre classes por meio de critérios mais objetivos. Esse método pode ser utilizado para identificar as áreas que possuem atributos semelhantes, para quantificar os padrões de variabilidade e reduzir a natureza empírica na definição de ZMs (LI et al., 2007).

A análise de agrupamento é uma técnica exploratória de dados que classifica uma ou mais variáveis em diferentes combinações de classes discretas (clusters), de tal forma que, objetos pertencentes ao mesmo grupo (cluster) devem ser mais semelhantes uns aos outros, ao passo que objetos em diferentes grupos são diferentes (ORTEGA; SANTIBÁÑEZ, 2007). Segundo Xin-Zhong et al. (2009), o objetivo é estatisticamente minimizar a variabilidade dentro do grupo e, ao mesmo tempo, maximizar a variabilidade entre grupos para produzir grupos homogêneos.

Para Ortega e Santibáñez (2007), algoritmos de agrupamento diferem nas medidas de semelhança utilizadas, na sua ponderação para definir o critério geral para ser otimizado pela classificação e no algoritmo utilizado para encontrar a melhor classificação. A análise de cluster é dividida em duas categorias principais: os métodos hierárquicos e não hierárquicos.

Um dos métodos de agrupamento não hierárquico bastante difundido na literatura (REYNIERS et al., 2006; TAYLOR et al., 2003; RODRIGUES JUNIOR et al., 2011; FRIDGEN et al., 2004) é o K-Means (C-Means), em que os dados multidimensionais são classificados em k classes (clusters). O centróide em cada classe tem a distância mínima de

cada ponto de dados. O algoritmo Fuzzy C-Means é uma extensão do K-means, sendo baseado na lógica fuzzy, definida por Zadeh (1965), e que responde por incertezas associadas às fronteiras de classe e associação (DOBERMANN et al., 2003). Para Guastaferro et al. (2010), Fuzzy C-Means e algoritmos de densidade não paramétricos são algumas das técnicas de agrupamento mais comumente utilizadas (MORARI et al., 2009; XIN-ZHONG et al., 2009; BAZZI et al., 2013; MILNE et al., 2012).

O funcionamento do algoritmo Fuzzy C-Means ocorre de forma que o algoritmo determina a associação em cada cluster através de um processo iterativo que começa com um centróide aleatório para cada cluster formado. Cada observação é atribuída ao mais próximo destes centróides. Novos centróides são, então, recalculados para cada grupo em função da distância (euclidiana, diagonal, ou mahalanobis). Para garantir a estabilidade do conjunto, o processo é repetido até que ou o critério de convergência especificado seja satisfeito ou o número máximo de iterações seja alcançado. O usuário especifica os números mínimo e máximo de agrupamentos (clusters), o número máximo de iterações, um critério de parada, o expoente (valor de ponderação ou imprecisão) e à distância métrica (FRIDGEN et al., 2000).

Vários pesquisadores encontraram bons resultados trabalhando com técnicas de agrupamento de dados. Fraisse et al. (2001), Li et al. (2007), Molin e Castro (2008) e Moral et al. (2010) utilizaram o Fuzzy C-means para definir ZMs com base em diversos atributos físicos e químicos do solo. Todos concluíram que as subáreas resultantes foram corretamente definidas, considerando as variabilidades espaciais e temporais da produtividade, além de serem úteis para a criação de planos de amostragem de solo.

3.8 Avaliação de zonas de manejo

Após executar o delineamento das ZMs, é importante que seja efetuada a avaliação das mesmas com o intuito de constatar se tal definição representa diferença significativa no potencial produtivo da cultura, ou seja, se cada unidade pode ser tratada como subárea de gerenciamento diferenciado do restante do talhão e se pode ser utilizada como fonte de recomendação e de análise para atributos do solo (MORAL et al., 2010; SALEH; BELAL, 2014).

Entre os métodos utilizados para avaliar as classificações definidas por meio de técnicas de agrupamentos fuzzy, destacam-se os indicadores de desempenho como o FPI (*Fuzziness Performance Index*), MPE (*Modified Partition Entropy*) (ODEH et al., 1992; BEZDEK, 1981), a Redução da Variância (VR) (DOBERMANN et al., 2003) e a Análise de Variância (ANOVA).

A redução de variância (DOBERMANN et al., 2003; XIANG et al., 2007) representa a redução do percentual da variância ao se dividir a área em ZMs. A expectativa é que a soma das variâncias dos dados das classes seja menor do que a variância total.

O índice de desempenho Fuzzy (FPI) (*Fuzziness Performance Index*) (ODEH et al., 1992; BOYDELL; MCBRATNEY, 2002) permite determinar o grau de separação entre as classes, ou seja, entre os c-clusters fuzzy de um conjunto de dados Y. Os valores de FPI variam entre 0 e 1. Quando os valores se aproximam de 0, significa que as classes são distintas com menor grau de compartilhamento dos dados entre elas, enquanto que valores próximos a 1 indicam não haver classes distintas, apresentando elevado grau de compartilhamento dos membros entre as classes (FRIDGEN et al., 2004). Já o índice da partição da entropia modificada (MPE) (Bezdek, 1981) é uma estimativa da quantidade de desorganização criada por um número específico de agrupamentos (FRIDGEN et al., 2000). Assim como o FPI ele também é limitado a valores entre 0 e 1. Valores de MPE próximos de 1 indicam que predomina a desorganização, enquanto que valores se aproximando de 0 indicam uma melhor organização (ODEH et al., 1992).

De acordo com Bazzi (2011), o teste de comparação de médias (ANOVA) pode ser aplicado para verificar se as subáreas geradas realmente representam grupos diferentes em um determinado nível de significância. Porém, para aplicá-lo, considera-se que as amostras são independentes dentro de cada unidade.

Para Tagarakis et al. (2013) e Fridgen et al. (2004), o número ideal de agrupamentos em um conjunto de dados é aquele que apresenta os menores valores para o FPI e MPE e máximo VR. Além do número ideal de ZMs, outros parâmetros podem influenciar na qualidade final das ZMs, como a utilização de diferentes variáveis para realizar o agrupamento, diferentes métodos de normalização dessas variáveis e uso de um ou outro método de interpolação para criação da grade amostral. Tais índices podem, então, avaliar qual o melhor conjunto de dados e quais os procedimentos adequados para geração das ZMs.

3.9 Desenvolvimento de software para agricultura

Segundo Sorensen et al. (2010a), o aumento no uso de computadores, internet e smartphones, em certo grau melhorou e facilitou a aquisição de informações e a tarefa de análise dessas. Isso vem como um facilitador para a AP, já que há uma demanda de grande quantidade de dados para realizar o gerenciamento da propriedade.

No entanto, a aquisição e a análise de informações ainda é uma tarefa difícil, uma vez que a informação é produzida a partir de várias fontes que podem não ser necessariamente interligadas (SORENSEN et al., 2010a). Isso faz com que se deixe uma

lacuna entre a aquisição dos dados e o uso eficiente destes nas decisões de gestão agrícolas (REICHARDT; JÜRGENS, 2009).

McCown (2002) argumenta que, na concepção de um sistema de informação aplicado à gestão agrícola, a ênfase deve ser voltada menos para o design e mais em aprender o que os agricultores necessitam e como eles agem. Além disso, não se deve utilizar apenas as experiências e o ponto de vista dos pesquisadores na projeção de tais sistemas, mas sim coletar a demanda dos agricultores. Para Sorensen et al. (2010b), a tendência é utilizar uma abordagem mais centrada no usuário no desenvolvimento de novas tecnologias.

Murakami et al. (2007) listaram os requisitos mais importantes para um sistema de informação aplicado à gestão agrícola: (a) um projeto que visa atender as necessidades específicas dos agricultores; (b) uma interface de usuário simples; (c) métodos de processamento de dados automatizados e simples de usar; (d) uma interface do usuário controlada, permitindo o acesso a funções de processamento e análise; (e) a integração de conhecimentos e preferências do usuário; (f) interoperabilidade; (g) escalabilidade; (h) capacidade de integração com outras aplicações; e (i) de baixo custo.

Para Nikkila et al. (2010), um sistema de informação voltado para a AP deve ser capaz de reconhecer vários formatos de dados e permitir a troca de dados com outras aplicações. Como a maioria dos sistemas disponíveis voltados à gestão agrícola são sistemas comerciais, muitos desses produtos não são compatíveis com outras ferramentas.

Os problemas de usabilidade em sistemas de informação agrícola são, na maioria das vezes, a interface, que não é intuitiva para os agricultores e agrônomos. Para Batte e Arnholt (2003), essa tem sido a causa provável para a adoção lenta da agricultura de precisão.

Nikkila et al. (2010) afirmaram ainda que softwares para gestão agrícola têm de ser concebidos e implementados de forma a fornecer aos usuários fácil utilização com a ajuda de documentação escrita e suporte ao usuário, pois o grupo de agricultores é muito heterogêneo, com diferentes níveis de conhecimento.

3.10 Análise e desenvolvimento de software para dispositivos móveis

No escopo da AP, há interesse considerável em relação ao desenvolvimento de sistemas computacionais que facilitem a execução de diversas atividades. Uma abordagem que pode ser empregada para o desenvolvimento desses softwares é organizada como uma sequência de etapas, ou seja: análise, projeto, codificação (programação), testes, implantação e manutenção. Trata-se de uma abordagem sistemática, que se tornou um padrão no mercado de desenvolvimento de sistemas por ser fortemente organizada e

focada na qualidade dos processos e do produto final (PRESSMAN, 2011; SOMMERVILLE, 2011).

A linguagem de modelagem unificada (UML) (BOOCH; RUMBAUGH; JACOBSON, 1999) é utilizada para descrever projetos de software (SCHACH, 2009), sendo, independente do processo, orientada a casos de usos, centrada na arquitetura, iterativa e incremental (BOOCH; RUMBAUGH; JACOBSON, 2006). Schach (2009) afirma que a UML é uma notação e não uma metodologia e, portanto, pode ser utilizada com qualquer metodologia de desenvolvimento de software. A UML 2.2 é formada por um conjunto de 14 diagramas que servem para realizar a representação de um software, facilitando, assim, o seu desenvolvimento e entendimento.

O Android consiste em uma plataforma de desenvolvimento para aplicativos móveis como smartphones e tablets e contém um sistema operacional baseado em Linux, uma interface visual rica, GPS, diversas aplicações já instaladas e ainda um ambiente de desenvolvimento bastante completo, inovador e flexível. O Android SDK é o software utilizado para desenvolver aplicações no Android, que apresenta um emulador para simular o celular, ferramentas utilitárias e uma interface de programação de aplicativos (API) completa para a linguagem Java, com todas as classes necessárias para desenvolver as aplicações (LECHETA, 2013).

4 REFERÊNCIAS

AJANOVIC, A. Biofuels versus food production: Does biofuels production increase food prices? **Energy**, online, v. 36, n. 4, p.1-7, 2010.

ALVES, E. D. L.; VECCHIA, F. A. S. Análise de diferentes métodos de interpolação para a precipitação pluvial no Estado de Goiás. **Revista Acta Scientiarum**, Maringá, v. 33, n. 2, p.193-197, 2011.

BATTE, M. T.; ARNHOLT, M. W. Precision farming adoption and use in Ohio: case studies of six leading-edge adopters. **Computers and Electronics in Agriculture**, online, v. 38, n. 2, p. 125-139, 2003.

BAZZI, C. L. **Software para definição e avaliação de unidades de manejo em agricultura de precisão**. 2011. 123 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel, 2011.

BAZZI, C. L.; SOUZA, E. G. de.; URIBE-OPAZO, M. A.; NÓBREGA, L. H. P.; ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, Jaboticabal, v. 33, n. 5, p. 952-964, 2013.

BEZDEK, J. C. **Patter recognition with fuzzy objective function algorithms**. New York: Plenum Press, 1981. 256 p.

BOOCH, G.; RUMBAUCH, J.; JACOBSON, I. **UML: guia do usuário**. 2 ed. Rio de Janeiro: Campus, 1999. 474 p.

BOOCH, G.; RUMBAUCH, J.; JACOBSON, I. **UML: guia do usuário**. 2 ed. Rio de Janeiro: Campus, 2006. 474 p.

BOYDELL, B.; MCBRATNEY, A. B.; Identifying potential within-field management zones from cotton yield estimates. **Precision Agriculture**, online, v. 3, n. 1, p. 9-23. 2002.

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

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

CARVALHO, L. A.; MEURER, I.; SILVA JUNIOR, C. A.; CENTURION, J. F. Spatial variability of soil physical properties in two management systems in sugarcane crop. **Engenharia Agrícola**, Jaboticabal, v. 32, n. 1, p. 60-68, 2012.

CASA, R.; CASTRIGNANÒ, A. Analysis of spatial relationships between soil and crop variables in a durum wheat field using a multivariate geostatistical approach. **European Journal of Agronomy**, Germany, v. 28, n. 3, p. 331-342, 2008.

CORÁ, J. E.; ARAUJO, A. V.; PEREIRA, G.T.; BERALDO, J. M.G. Variabilidade espacial de atributos do solo para adoção do sistema de agricultura de precisão na cultura de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 28, n. 6, p. 1013-1021, 2004.

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

CROOKSTON, R.K. Using decision cases to enhance technology transfer in precision agriculture. **Precision Agriculture**, online, p. 1117–1122, 1996.

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

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

DIACONO, M. D.; CASTRIGNANÒ, A.; TROCOLLI, A.; BENEDETTO, B. B.; RUBINO, P. Spatial and temporal variability of wheat grain yield and quality in a Mediterranean environment: a multivariate geostatistical approach. **Field Crops Research**, online, v. 131, n. 13, p. 49-62, 2012.

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

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

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

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

FERRAZ, G. A. E. S.; SILVA, F. M.; CARVALHO, F. M.; COSTA, P. A. N.; CARVALHO, L. C. C. Viabilidade econômica do sistema de adubação diferenciado comparado ao sistema de adubação convencional em lavoura cafeeira: um estudo de caso. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 5, p. 906-915, 2011.

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

FLEMING, K. L.; HEERMANN, D. F.; WESTFALL, D. G. Evaluating Soil Color with Farmer Input and Apparent Soil Electrical Conductivity for Management Zone Delineation. **Agronomy Journal**, Madison, v. 96, n. 6, p. 1581-1587, 2004.

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

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

FRIDGEN, J. J.; FRAISSE, C. W.; KITCHEN, N. R.; SUDDUTH, K. A. Delineation and analysis of site-specific management zones. In: II Internacional Conference on Geospatial Information in Agriculture and Forestry. **Anais...** Lake Buena Vista, Florida, 2000.

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.

FU, Q.; WANG, Z.; JIANG, Q. Delineating soil nutrient management zones based on fuzzy clustering optimized by PSO. **Mathematical and Computer Modelling**, online, v. 51, n. 1, p.1299-1305, 2010.

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

GUEDES, E. M. S.; FERNANDES, A. R.; LIMA, H. V.; SERRA, A. P.; COSTA, J. R.; GUEDES, R. S. Impacts of different management systems on the physical quality of an Amazonian Oxisol. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 36, n. 4, p. 1269-1278, 2012.

HEDLEY, C. The role of precision agriculture for improved nutrient management on farms. **Journal of the Science of Food and Agriculture**, v. 95, n.1, p. 12-19. 2015.

HÖRBE, T. A.; AMADO, T. J. C.; FERREIRA, A. O.; ALBA, P. J. Optimization of corn plant population according to management zones in Southern Brazil. **Precision Agriculture**, online, v. 14, n. 4, p. 450-465, 2013.

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

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

JOHANN, J. A.; OPAZO, M. A. U.; SOUZA, E. G.; 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, p. 212-219, 2004.

KHOSLA, R.; FLEMING, K.; DELGADO, J. A.; SHAVER, T. M.; WESTFALL, D. G. Use of site-specific management zones to improve nitrogen management for precision agriculture. **Journal of Soil and Water Conservation**, online, v. 57, n. 6, p. 513-518, 2002.

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

LECHETA, R. **Google Android: aprenda a criar aplicações para dispositivos móveis com o Android SDK**. 3 ed. São Paulo: Novatec Editora, 2013. 822 p.

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

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

LI, Y.; 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**, online, v. 56, n. 2, p.174-186, 2007.

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

MCCOWN, R. L. Changing systems for supporting farmers decisions: problems, paradigms and prospects. **Agricultural Systems**, online, v. 74, n. 1, p. 179-220, 2002.

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

MILNE, A. E.; WEBSTER, R.; GINSBURG, D.; KINDRED, D. Spatial multivariate classification of an arable Field into compact management zones based on past crop yields. **Computers and Eletronics in Agriculture**, online, v. 80, n. 1, p. 17-30, 2012.

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

MORAL, F. J.; TERRÓN, J. M.; REBOLLO, F. J. Site-specific management zones based on the Rasch model and geostatistical techniques. **Computers and Electronics in Agriculture**, online, v. 75, n. 2, p. 223-230, 2011.

MORAL, F. J.; TERRÓN, J. M.; SILVA, J. R. M. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. **Soil and Tillage Research**, online, v. 106, n. 2, p. 335-343, 2010.

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**, online, v. 68, n. 1, p. 97-107, 2009.

MURAKAMI, E.; SARAIVA, A. M.; RIBEIRO JUNIOR, L. C. M.; CUGNASCA, C. E.; HIRAKAWA, A. R.; CORREA, P. L.P. An infrastructure for the development of distributed servic-oriented information systems for precision agriculture. **Computers and Electronics in Agriculture**, online, v. 58, n. 1, p. 37-48, 2007.

NIKKILA, R.; SEILONEN, I., KOSKINEN, K. Software architecture for farm management information systems in precision agriculture. **Computers and Electronics in Agriculture**, online, v. 70, n. 2, p. 328-336, 2010.

NKOKA, F.; VELDWISCH, G. J.; BOLDING, A. Organisational Modalities of Farmer-led Irrigation Development in Tsanganano District, Mozambique. **Water Alternatives**, Montpellier, v. 7, n. 2, p. 414-433, 2014.

ODEH, I. O. A.; MCBRATNEY, A. B.; CHITTLEBOROUGH, D. J. Soil pattern recognition with fuzzy c-means: application to classification and soil-landform interrelationship. **Soil Science Society America Journal**, online, v. 56, n. 2, p. 505-516, 1992.

OLIVEIRA JÚNIOR, J. C. de; SOUZA, L. C. P.; MELO, V. F. Variabilidade de atributos físicos e químicos de solos da formação guabirota em diferentes unidades de amostragem. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 34, n. 5, p. 1491-1502, 2010.

ORTEGA, R. A.; SANTIBÁÑEZ, O. A. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. **Computers and Electronics in Agriculture**, online, v. 58, n. 1, p. 49-59, 2007.

PORTZ, G., MOLIN, J. P., JASPER, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. **Precision Agriculture**, online, v. 13, n. 1, p. 33-44, 2012.

PRESSMAN, R. S. **Engenharia de Software**: uma abordagem profissional. 7 ed. São Paulo: Artmed, 2011. 720 p.

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

RALISCH, R.; MIRANDA, T. M.; OKUMURA, R. S.; BARBOSA, G. M. de C.; GUIMARÃES, M. de F.; SCOPEL, E; BALBINO, L. C. Resistência à penetração de um Latossolo Vermelho Amarelo do Cerrado sob diferentes sistemas de manejo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 12, n. 4, p. 381-384, 2008.

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

REICHARDT, M.; JÜRGENS, C. Adoption and future perspective of precision farming in Germany: results of several surveys among different agricultural target groups. **Precision Agriculture**, online, v. 10, n. 1, p. 73-94, 2009.

REICHERT, J. M.; REINERT, D. J.; BRAIDA, J. A. Qualidade dos solos e sustentabilidade de sistemas agrícolas. **Revista Ciência & Ambiente**, v. 1, n. 27, p. 29-48, 2003.

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

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

SALEH, A.; BELAL, A. A. Delineation of site-specific management zones by fuzzy clustering of soil and topographic attributes: A case study of East Nile Delta, Egypt. **IOP Conference Series: Earth and Environmental Science**, Montreal, v. 18, n. 1, p. 1-6, 2014.

SCHACH, S. R. **Engenharia de Software**: os paradigmas clássico e orientado a objetos. 7 ed. Nova York: McGraw-Hill, 2009. 618 p.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHEPERS, J. S.; JOHSON, S. H.; LUCHIARI, A. Appropriateness of Management Zones for Characterizing Spatial Variability of Soil Properties and Irrigated Corn Yields across Years. **Agronomy Journal**, Madison, v. 96, n. 1, p. 195-203, 2004.

SOMMERVILLE, I. **Engenharia de Software**. 9 ed. São Paulo: Pearson, 2011. 529 p.

SORENSEN, C. G.; FOUNTAS, S.; NASH, E.; PESONEN, L.; BOCHTIS, D.; PEDERSEN, S. M.; BASSO, B.; BLACKMORE, S. B. Conceptual model of a future farm management information system. **Computers and Electronics in Agriculture**, online, v. 72, n. 1, p. 37-47, 2010a.

SORENSEN, C. G.; PESONEN, L.; FOUNTAS, S.; SUOMI, P.; BOCHTIS, D.; BILDSOE, P.; PEDERSEN, S. M. A user-centric approach for information modelling in arable farming. **Computers and Electronics in Agriculture**, online, v. 73, n. 1, p. 44-55, 2010b.

TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T.A. Management zones delineation using fuzzy clustering techniques in grapevines. **Precision Agriculture**, online, v. 14, n. 1, p. 18-39, 2013.

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

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

WANG, Y. Q.; SHAO, M. A. Spatial variability of soil physical properties in a region of the loess plateau of PR China subject to wind and water erosion. **Land Degradation & Development**, online, v. 24, p. 296-304, 2013.

WIRSENIUS, S.; AZAR, C.; BERNDES, G. How much land is needed for global food production under scenarios of dietary changes and livestock productivity increases in 2030? **Agricultural Systems**, online, v. 103, n. 9, p. 621-638, 2010.

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

XIN-ZHONG, W.; GUO-SHUN, L.; HONG-CHAO, H.; ZHEN-HAI, W.; QING-HUA, L.; XU-FENG, L.; WI-HONG, H.; YAN-TAO, L. Determination of management zones for a tobacco Field based on soil fertility. **Computers and Electronics in Agriculture**, online, v. 65, n. 2, p. 168-175, 2009.

ZADEH, L. A. Fuzzy sets. **Information and Control**, online, v. 8, n. 3, p. 338-353, 1965.

5 ARTIGO 1:

NORMALIZAÇÃO DE DADOS PARA DEFINIÇÃO DE ZONAS DE MANEJO

RESUMO: Zonas de manejo (ZMs) são consideradas uma alternativa economicamente viável para a aplicação da agricultura de precisão, por causa de seu baixo custo inicial e alto retorno em benefícios econômicos e ambientais. Técnicas de agrupamento de dados e o algoritmo Fuzzy C-Means são os processos mais utilizados para a definição de ZMs. A medida de similaridade mais comum utilizada é a distância euclidiana; no entanto, como o algoritmo Fuzzy C-Means é sensível à unidade de medida das variáveis de entrada, estas variáveis são tipicamente normalizadas, dividindo o valor pelo valor máximo, pela média, ou a soma das observações. O objetivo deste estudo foi avaliar a influência dos métodos de normalização de dados para definir ZMs. Os testes foram realizados em três áreas experimentais com 9,9, 15 e 19,8 ha, localizadas na região Oeste do estado do Paraná. As variáveis (atributos) utilizadas para definição das ZMs foram selecionadas por meio da matriz de correlação espacial e os dados foram normalizados utilizando os métodos escore padrão, amplitude e média. As ZMs foram definidas usando o algoritmo Fuzzy C-Means, para realizar os agrupamentos em duas, três e quatro classes. Os métodos de normalização foram avaliados por meio dos índices entropia da partição modificada (MPE), índice de desempenho fuzzy (FPI), redução de variância (VR), índice de suavidade(SI), índice kappa e ANOVA. Concluiu-se que quando são utilizadas mais de uma variável no processo de agrupamento em que a medida de similaridade é a distância euclidiana, a normalização é necessária. O método da amplitude foi considerado o melhor método de normalização.

PALAVRAS-CHAVE: agricultura de precisão; Fuzzy C-Means; Índice de suavidade; redução de variância.

THE IMPORTANCE OF NORMALIZATION OF DATA FOR DEFINING MANAGEMENT ZONES

ABSTRACT: Management zones (MZs) are an economically viable alternative to implement precision agriculture, due to its low initial cost and high yield in economic and environmental benefits. Data clustering techniques and the Fuzzy C-Means algorithm are the most widely used processes for defining MZs. The most common similarity measurement used is the Euclidean distance; however, because the algorithm is sensitive to the range of the input variables, these variables are typically normalized, dividing the value by the maximum value, by the mean, or sum of the observations. The objective of this study was to assess the influence of data normalization methods for defining MZs. Tests were conducted in three experimental fields with 9.9, 15.0, and 19.8 ha, located in Southern Brazil. The variables (attributes) used for defining MZs were selected using spatial correlation statistics and data were normalized using methods of standard score, range, and mean. The MZs were defined using the Fuzzy C-Means algorithm, which generated clusters of two, three, and four classes. The normalization methods were evaluated by some indexes (modified partition entropy [MPE], fuzziness performance index [FPI], variance reduction [VR], smooth index [SI], and kappa) and ANOVA. It was proved that when the MZs definition uses more than one variable in the clustering process whose similarity measure is the Euclidean distance, normalization is required. The range method was considered the overall best normalization method.

KEYWORDS: Fuzzy C-Means; precision agriculture; smooth index; variance reduction.

5.1 Introdução

O estudo da distribuição espacial dos atributos de solo e planta é importante para o estabelecimento de práticas adequadas de manejo, visando além da maximização da produtividade, a redução dos custos e a minimização de possíveis danos ambientais. Assim, a determinação das práticas de gestão adequadas e sua execução irão variar em diferentes regiões do talhão (TILMAN et al., 2011; LI et al., 2013; BANSOD; PANDEY, 2013; HEDLEY, 2015).

Uma zona de manejo (ZM) é definida como uma sub-região do talhão que apresenta combinação de fatores limitantes de produtividade e que são considerados semelhantes (TAGARAKIS et al., 2013). Isso facilita a aplicação das técnicas de agricultura de precisão (AP), por proporcionar a redução dos custos de adoção e aplicação, uma vez que ZMs podem utilizar equipamentos de taxa constante e permitir a amostragem inteligente. Realizar a divisão das ZMs não é uma tarefa simples, porque vários atributos (variáveis) podem influenciar o rendimento das culturas. Considerando que uma ZM deve ser utilizada durante vários anos, sugere-se que as variáveis consideradas devem ser temporalmente estáveis e que possuam influência sobre a produtividade. Entre as variáveis identificadas na literatura como potenciais para gerar zonas de manejo são a elevação (FRAISSE et al., 2001; JAYNES et al., 2005; PERALTA; COSTA, 2013; FARID et al., 2016; SCHEPERS et al., 2004), condutividade elétrica do solo (LI et al., 2007; FARID et al., 2016) e percentual de areia e argila no solo (FARID et al., 2016).

Várias técnicas para definição de ZMs são propostas na literatura, entre elas as apresentadas por Pedroso et al. (2010) e Xiang et al. (2007) em que duas abordagens foram adotadas essencialmente: 1) Corresponde aos métodos empíricos, sendo que nessa abordagem a distribuição da frequência de rendimento é utilizada para dividir o talhão em, normalmente, três ou quatro ZMs. Essa abordagem utiliza dados de rendimento das culturas para a definição das ZMs e baseia-se no fato de que este valor corresponde à resposta da cultura; em outras palavras, não se tem por objetivo identificar os atributos que afetam o rendimento. A exatidão destas técnicas melhora à medida que o número de safras utilizadas torna-se maior; 2) correspondente a técnicas de clusterização não supervisionada em que são utilizados os métodos de análise de cluster, que são altamente recomendados para a definição de ZMs (LI et al., 2007; ILIADIS et al., 2010). Nesta abordagem, vários atributos, tais como condutividade elétrica, resistência do solo a penetração, elevação, declividade e textura do solo e suas combinações são utilizadas. Embora qualquer atributo possa estar relacionado com o rendimento das culturas, Doerge (2000) sugere que o atributo ideal deve ser temporalmente estável e correlacionado com a produtividade. Os métodos mais comumente utilizados na definição de ZMs são os métodos de agrupamento, como o algoritmo K-means (RODRIGUES JR. et al., 2011; ORTEGA; SANTIBAÑEZ, 2007) e Fuzzy

C-Means (LI et al., 2007). As duas abordagens são diferenciadas pela robustez do método Fuzzy C-Means, que incorpora a teoria de lógica fuzzy no algoritmo de divisão.

A identificação de quais variáveis deverão ser utilizadas é uma etapa importante na definição de ZMs. Entre as técnicas comumente utilizadas estão o uso de análise de componentes principais (PCA) (BANSOD; PANDEY, 2013) e o uso da estatística de autocorrelação espacial bivariável de Moran, proposta por Czaplewski e Reich (1993), e utilizada por Reich et al. (1994) e Bonham et al. (1995). Bazzi et al. (2013) propuseram um método baseado na estatística bivariada de Moran, em que são eliminadas sequencialmente as variáveis que não possuem dependência espacial, que não têm correlação espacial com a produtividade e as redundantes (SOBJAK et al., 2016; GAVIOLI et al., 2016; SCHENATTO et al., 2016).

São bastante sugeridos na literatura métodos de agrupamento para divisão dos dados em grupos com características homogêneas, sendo que o que mais se destaca é o Fuzzy C-Means (LI et al., 2007; FU et al., 2010; ZHANG et al., 2013; LI et al., 2013; MORAL et al., 2010). Esse algoritmo usa um expoente de ponderação para controlar o grau de compartilhamento entre as classes (BEZDEK, 1981), permitindo que os indivíduos exibam adesão parcial em cada uma das classes, o que é importante ao estudar a variabilidade que ocorre em fenômenos naturais (BURROUGH, 1989). Antes de um conjunto de dados poder ser formado, é necessário estabelecer uma adequada medida de similaridade, sendo mais utilizada a distância euclidiana, que dá um peso igual a todas as variáveis medidas e é sensível às variáveis correlacionadas (BEZDEK, 1981).

Um problema metodológico é a decisão de se normalizar ou não as variáveis antes do processo de agrupamento quando se utiliza a distância euclidiana (MILLIGAN; COOPER, 1988). Esses autores estudaram sete formas de normalização, incluindo desvio padrão, média e amplitude da variável. Seus resultados indicaram que a divisão pela amplitude da variável obteve melhores resultados. Outros pesquisadores também recomendaram a normalização dos dados (SNEATH; SOKAL, 1973; ANDERBERG, 1973; LARSCHEID; BLACKMORE, 1996).

O objetivo desse estudo foi avaliar o desempenho de três diferentes técnicas de normalização de variáveis frequentemente utilizadas no processo de agrupamento de dados por meio do algoritmo Fuzzy C-Means para geração de ZMs.

5.2 Material e métodos

Essa pesquisa foi conduzida em três áreas agrícolas comerciais (Figura 1): Área A: 15 ha, localizada no município de Céu Azul/PR/Brasil, com localização geográfica central de 25°06'32" S e 53°49'55" O e altitude média de 460 m; Área B: com 9,9 ha, localizada no

município de Serranópolis do Iguçu/PR/Brasil, localização geográfica central de 25°24'28" S e 54°00'17" O, com altitude média de 355 m; Área C: com 19,8 ha, localizada no município de Cascavel/PR/Brasil, com localização geográfica central de 24°57'08" S e 53°33'59" O e altitude média de 650 m.

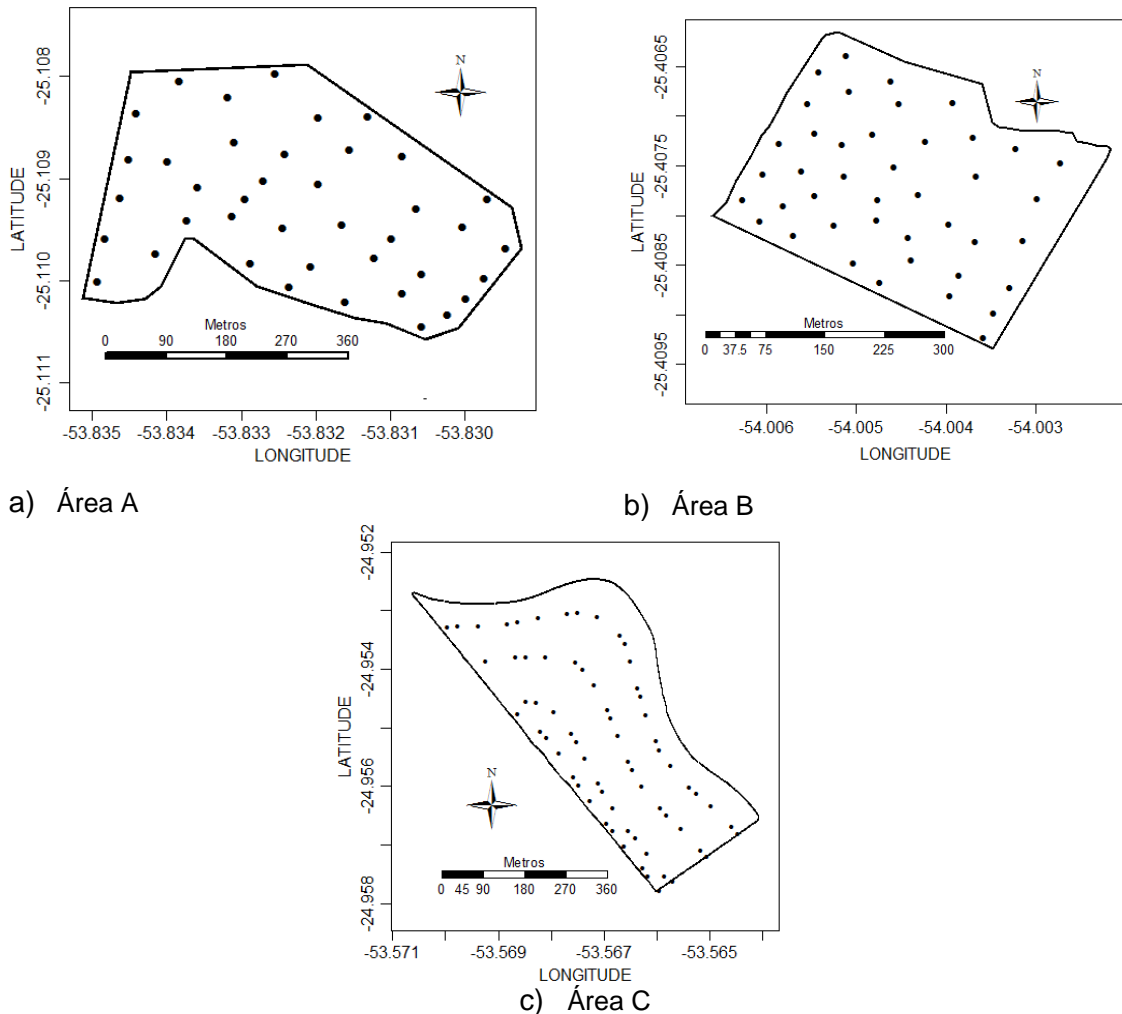


Figura 1 Áreas experimentais e pontos amostrais.

Os solos foram classificados como LATOSSOLO VERMELHO Distroférico típico (EMBRAPA, 2013) e cultivados em sistema de plantio direto com sequência de culturas soja, trigo, milho e aveia na área A e sucessão de culturas de soja e milho nas áreas B e C.

Na definição das ZMs foram utilizados atributos considerados temporalmente estáveis (Tabela 1). Foram excluídos os atributos químicos do solo, com base na recomendação da literatura (DOERGE, 2000). A fim de satisfazer as restrições da análise geoestatística (JOURNEL; HUIJBREGTS, 1978), quanto ao número mínimo de pares (30) para calcular as semivariâncias do semivariograma, utilizou-se uma grade amostral densa (Tabela 1), com 2,67 pontos ha⁻¹ para a área A, 4,24 pontos ha⁻¹ para a área B e 3,43 pontos ha⁻¹ para a área C. As grades amostrais irregulares foram definidas considerando a linha imaginária central entre as curvas de nível de cada área (Figura 1).

As variáveis e o período de coleta em cada área podem ser visualizados na Tabela 1. Para levantamento dos dados de elevação foi utilizada uma estação total eletrônica Topcon GPT-7505 e a resistência do solo à penetração (RSP) foi determinada por meio de um penetrógrafo Falker PGL 1020. As amostras de solo foram coletadas a uma profundidade de 0-0,2m e, então, encaminhadas para análise em laboratório.

Os dados de produtividade da soja para a área A, foram determinados por meio de um monitor de colheita CASE AFS PRO 600 acoplado em uma colhedora CASE modelo 2388. Já para as áreas B e C a produtividade foi determinada por meio da colheita manual de uma amostra de 1m² em cada um dos pontos de amostragem. Em todos os casos a produtividade foi corrigida para o teor de água de 13%. Para reduzir a variabilidade temporal dos dados de produtividade, que são fortemente influenciados pelo clima e pela precipitação pluviométrica, realizou-se a normalização dos dados de produtividade da soja (para as áreas A e C) e soja e milho (para a área B), fazendo uso da técnica de normalização escore padrão, gerando-se uma única variável do atributo produtividade. De acordo com Bunselmeyer e Lauer (2015), a ideia é usar o número máximo de valores de dados de produtividade, além disso, Jaynes et al. (2003) e Jaynes et al. (2005) afirmam que a soja e o milho apresentam um comportamento semelhante no campo, no que diz respeito ao seu potencial produtivo.

Tabela 1 Identificação dos tipos de atributos e períodos de coleta para cada área experimental

Atributos	Área A (40 amostras)			Área B (42 amostras)			Área C (68 amostras)	
	2012	2013	2014	2012	2013	2014	2010	2011
RSP 0,0 – 0,1 m (MPa)	X	X	X	X	X	X	X	
RSP 0,1 – 0,2 m (MPa)	X	X	X	X	X	X	X	
RSP 0,2 – 0,3 m (MPa)	X	X	X	X	X	X	X	
pH	X							
Elevação (m)	X			X			X	
Declividade (°)	X			X			X	
Densidade (g cm ⁻³)	X			X			X	
Areia (%)	X			X			X	
Silte (%)	X			X			X	
Argila (%)	X			X			X	
MO (%)	X			X			X	
Produtividade soja (t ha ⁻¹)	X	X	X	X	X	X	X	X
Produtividade do milho (t ha ⁻¹)					X	X		

RSP – resistência do solo a penetração; MO – Matéria orgânica.

A fim de avaliar a correlação espacial entre as variáveis foi utilizada a estatística de correlação espacial bivariada de Moran para criar uma matriz de correlação espacial através do software SDUM. A diagonal principal dessa matriz representa a dependência espacial de cada variável e os elementos restantes, isto é, a correlação cruzada de cada par de variáveis. Utilizando o método apresentado por Bazzi et al. (2013), foram eliminadas as variáveis que não possuem dependência espacial, as que não apresentam correlação

espacial com a produtividade e as variáveis redundantes (variáveis correlacionadas entre si, eliminando a variável menor correlacionada com a produtividade).

Na análise geoestatística das variáveis selecionadas, os dados foram ajustados ao semivariograma experimental por meio dos modelos esférico, exponencial e gaussiano, sendo a seleção do melhor modelo ajustado obtida por meio de estatísticas da validação cruzada (SUN et al., 2009; ARSLAN, 2012). Os dados foram então interpolados por krigagem, a fim de criar uma grade de 5 x 5 m com um número mais denso de pontos por área e, conseqüentemente, definir ZMs mais suaves.

O algoritmo Fuzzy C-Means foi utilizado para realizar a criação das ZMs, devido a esse algoritmo possuir ampla aceitação (ILIADIS et al., 2010; ARNO et al., 2011; VALENTE et al., 2012; LI et al., 2013), e oferecer bons resultados (JIPKATE; GOHOKAR, 2012; MINGOTI; LIMA, 2006), considerando ainda que pode realizar o zoneamento automaticamente, formando agrupamentos (clusters), sem a subjetividade da divisão em classes escolhidas pelo técnico (FRIDGEN et al., 2004) e permitir a divisão de um conjunto de dados em C-clusters, tendo como referência um centro de massa ou centróide para cada cluster formado (FRIDGEN et al., 2004).

Estatisticamente, a técnica Fuzzy C-means minimiza a soma dos quadrados dos erros dentro de cada classe, seguindo alguns critérios e os dados são agrupados de forma iterativa para a classe mais próxima pelo critério da distância mínima. O método considera um conjunto de dados $X = \{x_1, x_2, \dots, x_n\}$ onde x_k , corresponde a um vetor de características $x_k = \{x_{k1}, x_{k2}, \dots, x_{kp}\} \in R^p$ para todo $k \in \{1, 2, \dots, n\}$, sendo R^p o espaço p-dimensional. Busca-se encontrar uma pseudo-partição Fuzzy que corresponde a uma família de C conjuntos Fuzzy de X, que representa a estrutura dos dados da melhor forma possível e é denotado por $P = \{A_1, A_2, \dots, A_C\}$, que satisfaz $\sum_{i=1}^c A_i(x_k) = 1$ e $0 < \sum_{i=1}^c A_i(x_k) < n$, em que $k \in \{1, 2, \dots, n\}$, e n representa o número de elementos de X. O algoritmo se orienta com parâmetros referentes ao número de agrupamentos que se deseja ter (C), uma medida de distância que define a distância permitida entre os pontos e os centróides ($m \in (1, \infty)$) e um erro utilizado como critério de parada ($\varepsilon > 0$) (BEZDEK, 1981).

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

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

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

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

em que, $\|x_k - v_i^{(t)}\|^2$ representa a distância entre x_k e v_i .

Como a distância entre cada ponto n dimensional e o centroide (também n dimensional) é calculada em função dos valores de cada elemento apresentado na matriz de dados de entrada, quando estes elementos são apresentados com valores em unidades de medida distintas (por exemplo, elevação em metros, RSP em kPa ou MPa, argila, areia e silte em %), o cálculo da distância euclidiana gerada pode apresentar valores incorretos devido às diferentes unidades métricas que representam cada elemento. Por meio da Figura 2 é representado o exemplo da influência da não padronização dos dados que servem como entrada para o algoritmo Fuzzy C-Means. Para exemplificar, são apresentados como entrada, dados de argila (%) e elevação – sendo representado em metros (a) e representado em Km (b). Por meio da Figura 2, é possível verificar que caso a variável elevação for informada em metros, o vetor V_1 , que indica os elementos mais próximos ao centroide 1, recebe como elementos os pontos A e E, considerando que estes elementos encontram-se mais próximos deste centroide. Já os demais elementos encontram-se mais próximos do centroide 2, sendo relacionados ao vetor V_2 . Quando informados os dados de elevação em km, apesar dos dados se apresentarem na mesma distribuição, verifica-se que devido à mudança de unidade métrica, os elementos mais próximos do centroide 1 passam a ser os pontos C e D. Dessa forma, verifica-se a importância em se aplicar métodos de normalização de dados antes desses servirem de entrada para o algoritmo de clusterização.

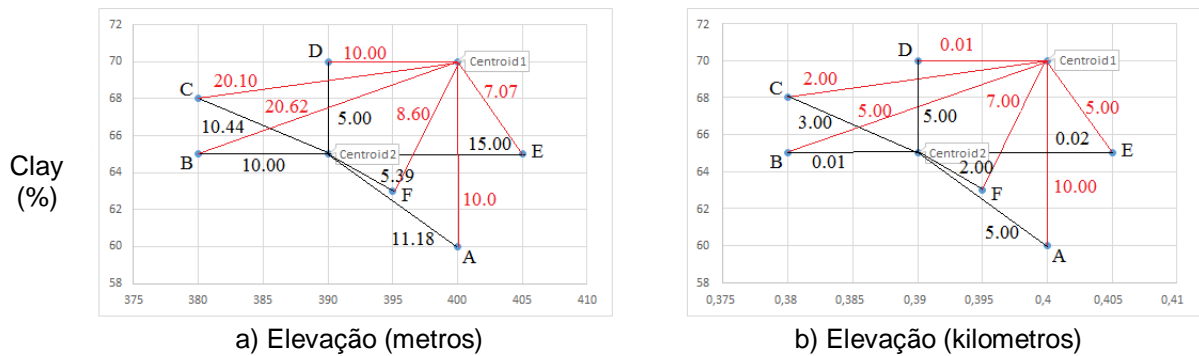


Figura 2 Representação da diferença que ocorre no cálculo da distância euclidiana quando utilizadas diferentes unidades de medida.

Com os mapas gerados pela krigagem, foram avaliados três métodos de normalização de dados para cada uma das três áreas estudadas, sendo:

- 1) Método do Escore Padrão (Equação 3) (LARSCHEID; BLACKMORE, 1996)

$$P_{iN} = \frac{(P_i - \bar{P})}{S} \quad \text{Eq. (3)}$$

em que, P_{iN} - pixel i normalizado; P_i - pixel i a ser normalizado; \bar{P} - média aritmética de todos os pixels do mapa a ser normalizado; S - desvio padrão de todos os pixels do mapa a ser normalizado.

- 2) Método da amplitude (Equação 4) (MIEKLE; BERRY, 2007)

$$P_{iN} = \frac{(P_i - \text{Mediana})}{\text{Amplitude}} \quad \text{Eq. (4)}$$

em que, P_{iN} - pixel i normalizado; P_i - pixel i a ser normalizado.

Este método se baseia na amplitude do conjunto de dados. Algumas alterações neste método decorrem sobre o numerador (MILLIGAN; COOPER, 1988). Estes autores apresentam no numerador somente o valor do dado P_i ou $P_i - P_{i_{\text{mínimo}}}$, sendo que, nesse caso, verifica-se que os dados normalizados se encontrarão entre os valores 0 e 1.

- 3) Método da Média (Equação 5) (SWINDEL, 1997)

$$P_{iN} = \frac{P_i}{\bar{P}} \quad \text{Eq. (5)}$$

em que, P_{iN} - pixel i normalizado; P_i - pixel i a ser normalizado; \bar{P} - média aritmética de todos os pixels do mapa a ser normalizado.

Esse método é bastante conhecido e utilizado, ele leva em conta que a média representa bem o conjunto de dados, mas o valor da média é sensível e pode ser alterado

por adição de qualquer constante, alterando-se facilmente a distribuição dos dados normalizados (ANDERBERG, 1973).

Após realizar a normalização de todas as variáveis, o algoritmo Fuzzy C-Means foi utilizado para definição das ZMs considerando duas, três e quatro sub-regiões nas áreas A, B e C, respectivamente. Foram geradas também ZMs sem aplicar os processos de normalização nos dados de entrada, visando comparar com os demais métodos avaliados.

Para a avaliação das ZMs foram empregados os seguintes índices e a ANOVA:

1) Redução da Variância (VR) (DOBERMANN et al., 2003; XIANG et al., 2007), Equação 6: Esse índice foi utilizado para a variável produtividade média normalizada, com a expectativa que a soma das variâncias dos dados de cada zona de manejo seja menor que a variância total.

$$RV = 1 - \frac{\sum_{i=1}^c (W_i * V_{um_i})}{V_{\acute{a}rea}} * 100 \quad \text{Eq. (6)}$$

em que, c - número de zonas de manejo; W_i - proporção da área em cada zona de manejo. V_{um_i} - variância dos dados de cada zona de manejo; $V_{\acute{a}rea}$ - variância da amostra dos dados para toda a área.

2) Índice de Desempenho Fuzzy (Fuzziness Performance Index (FPI)), Equação 7: o qual permite determinar o grau de separação (isto é, confusão) entre os c -clusters fuzzy de um conjunto de dados X . Quando os valores de FPI se aproximam de 0 indicam classes distintas, apresentando pequeno grau de compartilhamento dos membros (dados) entre elas, enquanto que valores próximos a 1 indicam não haver classes distintas, apresentando elevado grau de compartilhamento dos membros entre as classes (FRIDGEN et al., 2004).

$$FPI = 1 - \frac{c}{(c-1)} \left[1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad \text{Eq. (7)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elemento ij da matriz de pertinência fuzzy.

3) Índice da Partição da Entropia Modificada (Modified Partition Entropy (MPE)), Equação 8: Esse índice estima a quantidade de desorganização criada por um número específico de clusters. Valores de MPE próximos de 1 indicam que predomina a desorganização, enquanto que valores se aproximando de 0 indicam melhor organização (BOYDELL; MCBRATNEY, 2002).

$$MPE = \frac{- \sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) / n}{\log c} \quad \text{Eq. (8)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elemento ij da matriz de pertinência fuzzy.

4) Índice de Suavidade (Smooth Index (SI)), Equação 9: calcula a frequência de mudança das classes do mapa temático nas direções horizontal, vertical e das diagonais, pixel a pixel. Na hipótese de o mapa possuir uma área totalmente homogênea, o resultado seria um índice de suavidade igual a 100%, devido à ausência de mudanças de classe. Da mesma forma, se o mapa fosse completamente gerado com valores aleatórios, o índice de suavidade apresentaria um valor próximo a zero.

$$SI = 100 - \left(\left(\frac{\sum_{i=1}^k NM_{Hi}}{4P_H} + \frac{\sum_{j=1}^k NM_{Vj}}{4P_V} + \frac{\sum_{l=1}^k NM_{Ddl}}{4P_{Dd}} + \frac{\sum_{m=1}^k NM_{Dem}}{4P_{De}} \right) * 100 \right) \quad \text{Eq. (9)}$$

em que, NM_{Hi} - número de mudanças na linha i (horizontal); NM_{Vj} - número de mudanças na coluna j (vertical); NM_{Ddl} - número de mudanças na diagonal l (diagonal direita - Dd); NM_{Dem} - número de mudanças na diagonal m (diagonal esquerda - De); k - número máximo de pixels na linha, coluna ou diagonais; P_H - possibilidade de mudanças de pixels na horizontal; P_V - possibilidade de mudanças de pixels na vertical; P_{Dd} - possibilidade de mudanças na diagonal direita - Dd ; P_{De} - possibilidade de mudanças na diagonal esquerda - De .

As ZMs geradas a partir de dados não normalizados e normalizados pelos três métodos (escore padrão, amplitude e média) foram comparadas por meio do índice Kappa (K, Equação 10) avaliando-se o grau de concordância, fazendo uso da escala: quando $0 < K \leq 0,2$, não possui concordância, quando $0,2 < K \leq 0,4$, fraca, quando $0,4 < K \leq 0,6$, moderada, quando $0,6 < K \leq 0,8$, forte, e quando $0,8 < K \leq 1$, muito forte (LANDIS; KOCH, 1977).

$$K = \frac{\left\{ n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i}) \right\}}{\left\{ n^2 - \sum_{i=1}^r (x_{i+} * x_{+i}) \right\}} \quad \text{Eq. (10)}$$

em que, K - índice Kappa de concordância; n - número total de observações (pontos amostrais); r - número de classes da matriz de erro; x_{ii} - número de combinações na diagonal; x_{i+} - total de observações na linha i ; x_{+i} - total de observações na coluna i .

5.3 Resultados e discussão

Por meio da matriz de correlação espacial, foram selecionadas as variáveis que apresentaram correlação espacial com a produtividade: elevação, areia, argila, RSP 0,0-0,1 (2013) e RSP 0,2-0,3 (2014) para a área A; silte, areia, elevação, RSP 0,0-0,1 (2012), RSP

0,0-0,1 (2013), RSP 0,0-0,1 (2014), e RSP 0,2-0,3 (2012) na área B; e RSP 0,1-0,2, RSP 0,2-0,3, elevação, declividade, areia e argila para a área C. Em seguida, as variáveis que não apresentaram correlação espacial com a produtividade foram eliminadas: RSP 0,2-0,3 (2014) para a área A; silte, argila, RSP 0,0-0,1 (2013) e RSP 0,0-0,1 (2014) para a área B; e declividade na área C. Por fim, foram eliminadas as variáveis redundantes: areia e silte para a área A; RSP 0,2-0,3 (2012) para a área B; e RSP 0,1-0,2, RSP 0,2-0,3, silte e argila na área C. Dessa forma, os resultados do processo de seleção de variáveis para definir as ZMs foram: a variável elevação para as três áreas em estudo (Tabela 2) e a variável RSP na profundidade de 0,0-0,1 m para as áreas A e B.

Tabela 2 Esquema de seleção e eliminação de variáveis (atributos) para geração de zona de manejo

Atributos	Área A			Área B			Área C
	2012	2013	2014	2012	2013	2014	2010
RSP 0,0 – 0,1 m (MPa)		X	X	X	X	X	X
RSP 0,1 – 0,2 m (MPa)		X	X	X	X	X	X
RSP 0,2 – 0,3 m (MPa)		X	X	X	X	X	X
pH	X			X			X
Elevação (m)	X			X			X
Declividade (°)	X						X
Densidade (g cm ⁻³)	X						X
Areia (%)	X			X			X
Silte (%)	X			X			X
Argila (%)	X			X			X
MO (%)				X			

[] - Eliminados por não apresentarem autocorrelação espacial; [] - Eliminados por não apresentarem correlação espacial com a produtividade; [] - Eliminados por serem redundantes; [] - Selecionadas para geração das ZMs.

A escolha dessas variáveis está de acordo com os resultados encontrados por outros autores (PERALTA et al., 2013), que encontraram correlação espacial entre a elevação e as propriedades físicas do solo com a produtividade da soja e do trigo. De acordo com os autores, essas variáveis podem ser consideradas na definição de ZMs para aplicação de diferentes práticas agrônômicas. Bons resultados na definição de ZMs também foram obtidos em campos cultivados com soja e milho, usando dados de elevação e condutividade elétrica do solo (JAYNES et al., 2005).

Foi realizada a análise geostatística das variáveis selecionadas (Elevação e RSP 0,0 – 0,1 m para as áreas A e B; Elevação para a área C) para interpolar os dados por krigagem ordinária. O modelo esférico foi o melhor ajustado para os dados de elevação da área A e o exponencial para os demais conjuntos de dados, segundo os resultados obtidos na validação cruzada.

Tabela 3 Análise geoestatística das variáveis selecionadas para geração das ZMs

Variável (Atributo)	Área	Modelo	Efeito Pepita	Patamar	Alcance
Elevação	A	Esférico	0	54,75	220,88
RSP 0,0 – 0,1 m (2013)	A	Exponencial	8538	1872	570,94
Elevação	B	Exponencial	12,68	37,49	355,59
SPR 0,0 – 0,1 m (2012)	B	Exponencial	4523	16544	124,71
Elevação	C	Exponencial	0,19	12,53	450,41

As variáveis foram então normalizadas (métodos escore padrão, amplitude e média) e importadas para o SDUM (Software de Definição de Unidades de Manejo) (BAZZI et al., 2013) para definição das ZMs (Figuras 3 a 6). Para as áreas A e B (quando foi utilizada mais de uma variável) verificou-se visualmente uma melhor definição das ZMs quando se utilizou o método da amplitude. Entretanto, quando foi utilizada somente uma variável (área C), não se verificou influência do tipo de normalização. Este fato era esperado porque a distância euclidiana, utilizada na definição das ZMs, é sensível a variáveis com amplitudes diferentes (BEZDEK, 1981; MILLIGAN; COOPER, 1988).

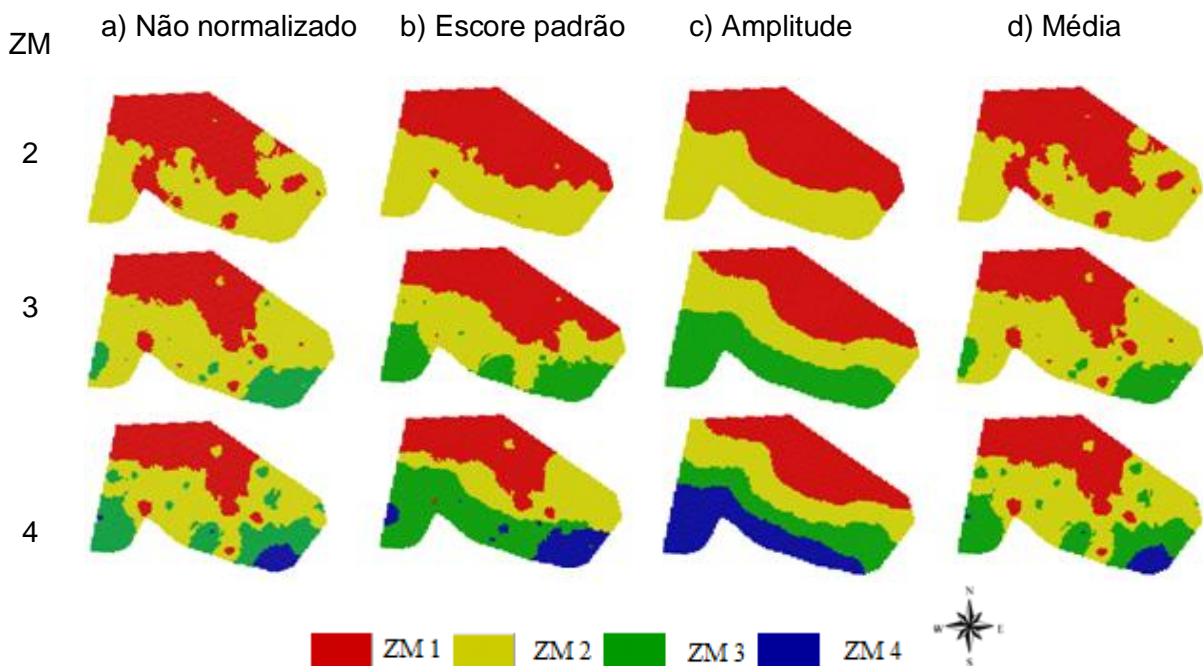


Figura 3 Zonas de manejo para a área A, geradas com os atributos altitude (m) e RSP 0-0,1 m (MPa) (2013), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).

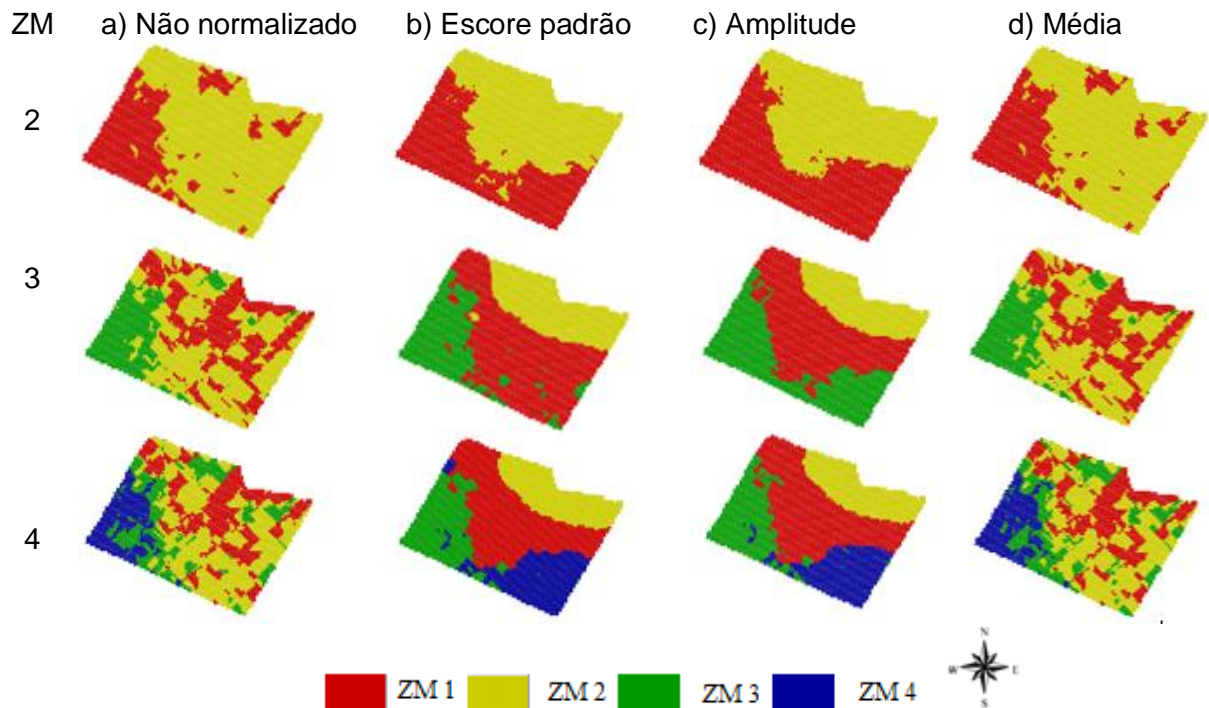


Figura 4 Zonas de manejo para a área B, geradas com os atributos altitude (m) e RSP 0-0,1 m (MPa) (2012), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).

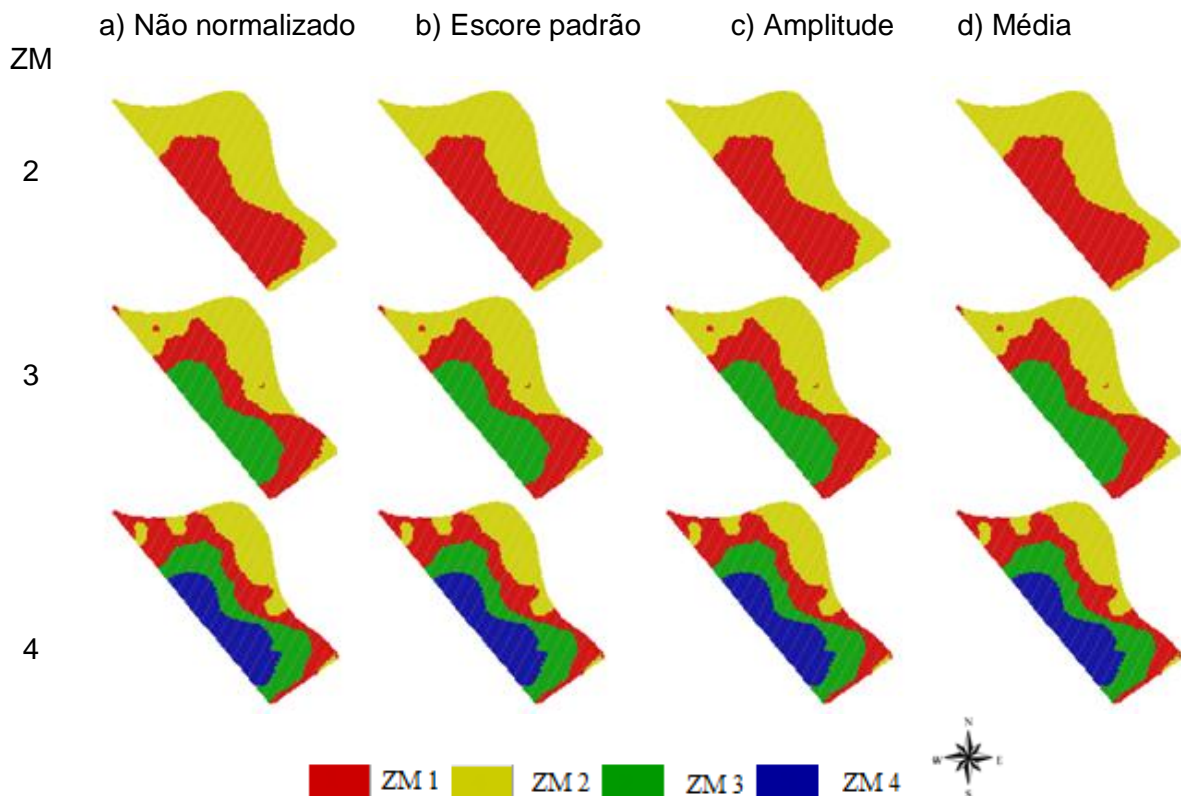


Figura 5 Zonas de manejo para a área C, geradas com o atributo altitude (m), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).

Para a área B também gerou-se zonas de manejo utilizando elevação em metros e RSP em kPa (Figura 6) para ilustrar a influência da unidade de medida dos dados de variáveis não normalizadas. Verificou-se que quando realizada a alteração da medida de RSP em MPa para kPa (dados de RSP variam de 1,300 a 1,631 kPa e 1.3 a 1.631 MPa), quando os dados foram normalizados todos os métodos apresentaram os mesmos resultados, o que não ocorreu para os dados não normalizados (comparar Figuras 4 e 6). Isso não significa que todos os métodos de normalização deram os mesmos resultados, mas que, quando qualquer método é utilizado, os mesmos resultados serão obtidos mesmo ao mudar as unidades de medida dos dados de entrada, pois são linearmente correlacionados.

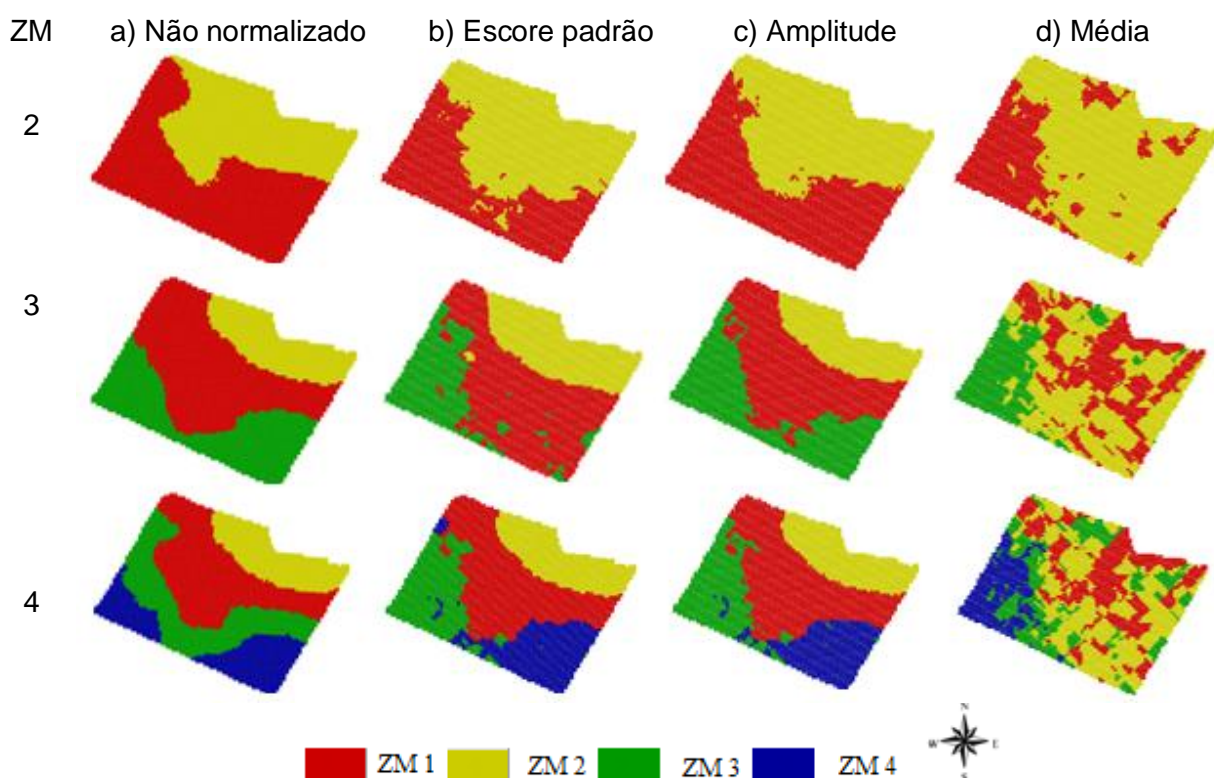


Figura 6 Zonas de manejo para a área B, geradas com os atributos altitude (m) e RSP 0-0,1 m (kPa) (2012), considerando os dados originais (a) e dados normalizados pelos métodos escore padrão (b), amplitude (c) e média (d).

Para as áreas A e B, verificou-se que houve maior redução da variância (Tabela 4) quando as áreas foram divididas em apenas duas zonas de manejo e utilizando o método amplitude (VR=42,5 e VR=6,5%, respectivamente). Para a área C, a divisão que apresentou melhores resultados para VR foi na divisão em quatro ZMs (VR=30,1), não havendo distinção entre os métodos de normalização.

Por meio da Anova, foi possível verificar que quando geradas duas ZMs obteve-se produtividades médias distintas nas áreas A e C, mas para a área A isso foi possível somente quando os dados foram normalizados pelo escore padrão e amplitude. Na área C, quando geradas mais de duas ZMs, apesar de haver aumento da redução da variância, não

foi possível identificar por meio da Anova, produtividades distintas. Na área B, apesar de ocorrer variação da variância quando os dados foram normalizados pelos métodos escore padrão e amplitude (VR=2,9% e VR=6,5%), verificou-se que em média as produtividades foram iguais.

Tabela 4 Índices de avaliação calculados para diferentes métodos de normalização em cada área

Área	Nº Zonas	Método de normalização	Anova				VR%	FPI	MPE	SI%
			ZM 1	ZM 2	ZM 3	ZM 4				
A	2	Não normalizado	a	a			8,3	0,12	0,02	95,03
		Escore padrão	a	b			15,3	0,12	0,02	97,74
		Amplitude	a	b			42,5	0,09	0,02	98,47
		Média	a	a			8,3	0,12	0,02	95,16
	3	Não normalizado	a	ac	bc		4,8	0,10	0,02	95,07
		Escore padrão	a	ac	bc		17,4	0,21	0,04	95,75
		Amplitude	a	a	b		25,4	0,14	0,03	97,02
		Média	a	ac	bc		4,8	0,10	0,02	95,04
	4	Não normalizado	a	bd	ad	c	36,7	0,12	0,03	93,31
		Escore padrão	a	ac	b	bc	28,6	0,21	0,05	95,02
		Amplitude	a	a	b	b	32,9	0,19	0,04	95,69
		Média	a	a	bc	ac	32,9	0,18	0,04	90,69
B	2	Não normalizado	a	a			-3,1	0,08	0,02	93,29
		Escore padrão	a	a			2,9	0,17	0,03	95,93
		Amplitude	a	a			6,5	0,16	0,03	96,92
		Média	a	a			0,0	0,09	0,02	93,21
	3	Não normalizado	a	a	a		2,0	0,11	0,03	82,85
		Escore padrão	ac	a	bc		1,0	0,23	0,05	93,95
		Amplitude	a	ac	bc		5,7	0,19	0,04	95,10
		Média	a	a	a		2,0	0,15	0,03	82,96
	4	Não normalizado	a	a	a	a	-11,1	0,12	0,03	78,47
		Escore padrão	ac	a	bc	ac	5,7	0,23	0,05	94,13
		Amplitude	a	ac	bc	ac	3,8	0,19	0,05	93,80
		Média	a	a	a	a	-9,9	0,18	0,04	77,87
C	2	Não normalizado	a	b			27,0	0,08	0,02	98,07
		Escore padrão	a	b			27,0	0,08	0,02	98,07
		Amplitude	a	b			27,0	0,08	0,02	98,07
		Média	a	b			27,0	0,50	0,08	98,07
	3	Não normalizado	a	b	b		27,5	0,10	0,02	96,47
		Escore padrão	a	b	b		27,5	0,10	0,02	96,47
		Amplitude	a	b	b		27,5	0,10	0,02	96,47
		Média	a	b	b		27,5	0,10	0,02	96,47
	4	Não normalizado	a	a	a	b	30,1	0,12	0,02	94,60
		Escore padrão	a	a	a	b	30,1	0,12	0,02	94,60
		Amplitude	a	a	a	b	30,1	0,12	0,02	94,60
		Média	a	a	a	b	30,1	0,12	0,02	94,60

ZM: Zona de Manejo; VR%: Redução da Variância; FPI: Índice de Desempenho Fuzzy; MPE: Índice de Partição da Entropia Modificada; SI%: Índice de suavidade.

Os índices MPE e FPI apresentaram resultados diversos para cada conjunto de dados normalizados, indicando que o processo de normalização influencia de forma significativa nos resultados do agrupamento (Figura 7). Para todas as áreas, independente de método de normalização, estes índices apresentaram como melhor agrupamento a

divisão em duas ZMs, com exceção da área A que apresentou melhores resultados para a divisão em três ZMs, quando utilizados os dados não normalizados e normalizados pela média. O método de normalização interferiu nos índices analisados (figura 7; VR, FPI, e MPE) quando havia mais de uma variável, como já foi demonstrado na Tabela 4. O comportamento do FPI e MPE foram bastante semelhantes, proporcionando a mesma interpretação (exceto para campo B com dados não-normalizados). A normalização pela amplitude foi o método (exceto para pequena inconsistência no campo C) em que a escolha do melhor número de zonas coincidiu nas três áreas.

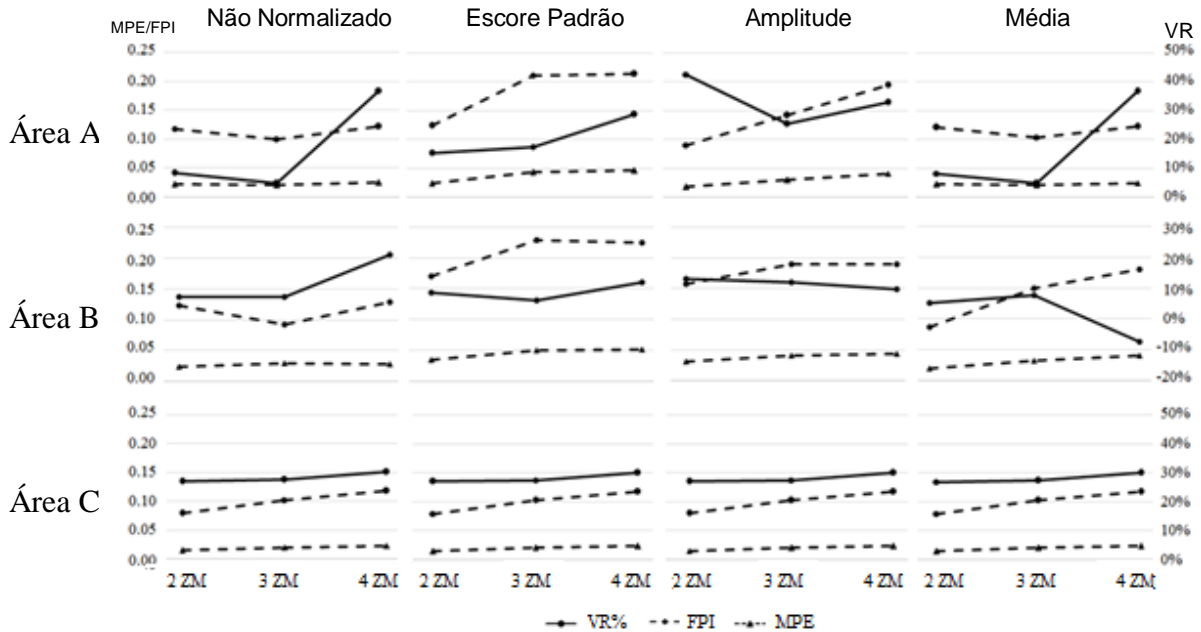


Figura 7 Estatísticas de VR(%); FPI e MPE obtidas na clusterização das áreas A, B e C.

O índice de suavidade (Figura 8) diminuiu à medida que o número de ZMs foi aumentando indicando uma suavidade dos mapas reduzida, o que complica a interpretação visual e a gestão específica local de fatores da produção agrícola. Perfeita concordância entre os métodos de normalização ocorreu na área C (ZMs definidas usando uma única variável), como esperado, concordando com os dados ilustrados na Figura 5. Os métodos desvio padrão e amplitude apresentaram um comportamento semelhante em todos os casos, com ligeiras vantagens para a amplitude. Além disso, média e dados não normalizados se comportaram de forma pior do que os outros métodos.




Figura 8 Índice de suavidade calculados para as áreas A, B e C, em função dos métodos de normalização.

O Índice Kappa (Figura 9) mostrou concordância perfeita entre as ZMs para a área C (ZMs definidas usando uma única variável), concordando com resultados apresentados na Figura 5. Para as áreas A e B (ZMs definidas com mais de uma variável), a concordância entre ZMs diminuiu à medida que o número de zonas foi aumentado. Ao utilizar mais de uma variável na definição das ZMs, houve dois casos: 1. Quando duas variáveis não foram significativamente diferentes em magnitude (Área A), os métodos não normalizado e média mostraram concordância perfeita (kappa = 1), e não normalizado e amplitude mostraram concordância fraca; 2. Quando as duas variáveis tiveram grandezas significativamente diferentes (área B), os métodos amplitude e escore padrão exibiram uma boa concordância, e a média mostrou menor concordância com os outros métodos. Vale ressaltar que o Índice Kappa não pode ser usado para indicar qual método de normalização é melhor se dois métodos forneceram mapas semelhantes.




Figura 9 Gráficos do índice Kappa de comparação das ZMs. N.N – Não normalizado; S.S. Método de normalização escore padrão.

5.4 Conclusões

Quando se utilizou mais de uma variável como dados de entrada para a definição de zonas de manejo fazendo uso do algoritmo Fuzzy C-Means (áreas A e B), os métodos de normalização influenciaram no processo de clusterização, gerando mapas de zonas de manejo diferentes quando comparados entre si e quando comparados com os mapas gerados sem o uso de nenhuma técnica de normalização. Esse fato indica que cada método tem suas particularidades e influenciou os dados de forma distinta. Quando utilizada somente uma variável (área C), não houve diferença nos mapas gerados quando não aplicado ou aplicado qualquer métodos de normalização.

O número de zonas selecionadas como melhor opção por meio dos índices (MPE, FPI, VR e ANOVA) foi o mesmo para cada método aplicado. O método de normalização pela amplitude foi o que apresentou melhores resultados de VR, indicando que os dados de produtividade foram melhor separados entre as zonas geradas. Nas áreas que foram selecionadas mais de uma variável (A e B), as zonas de manejo que apresentaram menor fragmentação (maior suavidade) foram as geradas pelo método amplitude e a maior fragmentação pelo método da média.

Verificou-se que quando utilizada mais de uma variável (áreas A e B), o método de normalização que menos influenciou os resultados quando comparados com os resultados obtidos com dados não normalizados foi o da média, sendo gerados mapas similares, conforme análise do índice Kappa (variando entre 0,95 e 1,00 para praticamente todos os casos). No caso de uma única variável ser utilizada (Área C), os métodos não influenciaram os resultados, sendo gerados mapas idênticos para os quatro casos (não normalizado, escore padrão, amplitude e média).

5.5 Referências

- ANDERBERG, M. R. **Cluster analysis for applications**. New York, NY: Academic Press, 1973. 255 p.
- ARNO, J.; MARTINEZ-CASASNOVAS, J. A.; RIBES-DASI, M.; ROSELL, J. R. Clustering of grape yield maps to delineate site-specific management zones. **Spanish Journal of Agricultural Research**, online, v. 9, n. 3, p. 721-729, 2011.
- ARSLAN, H. Spatial and temporal mapping of groundwater salinity using ordinary kriging and indicator kriging: The case of Bafra Plain, Turkey. **Agriculture Water Management**, online, v. 113 n. 1, p. 57-63, 2012.
- BANSOD, B. S.; PANDEY, O. P. An Application of PCA and Fuzzy C-Means to Delineate Management Zones and Variability Analysis of soil. **Eurasian Soil Science**, online, v. 46, n. 5, p. 556-564, 2013.
- BAZZI, C. L.; SOUZA, E. G.; URIBE-OPAZO, M. A.; NOBREGA, L. H. P.; ROCHA, D. M. Management Zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, Jaboticabal, v. 33, n. 5, p. 952-964, 2013.
- BEZDEK, J. C. **Pattern recognition with fuzzy objective function algorithms**. New York, NY: Springer US, 1981. 253 p.
- BONHAM, C. D.; REICH, R. M.; LEADER, K. K. Spatial cross-correlation of *Bouteloua gracilis* with site factor. **Grassland Science**, Japão, v. 41, n. 1, p. 196-201, 1995.
- BOYDELL, B.; MCBRATNEY, A. B. Identifying potential within-field management zones from cotton yield estimates. **Precision Agriculture**, online, v. 3, n. 1, p. 9-23, 2002.
- BUNSELMEYER, H. A.; LAUER, J. G. Using Corn and Soybean Yield History to Predict Subfield Yield Response. **Agronomy Journal**, Madison, v. 107, n. 2, p. 558-562, 2015.
- BURROUGH, P. A. Fuzzy mathematical methods for soil survey and land evaluation. **European Journal of Soil Science**, online, v. 40, n. 3, p. 477-492, 1989.
- CZAPLEWSKI, R. L.; REICH, R. M. **Expected value and variance of Moran's bivariate spatial autocorrelation statistic under permutation**. Fort Collins, CO: Research Paper, 1993. 24 p.
- DOBERMANN, A.; PING, J. L.; ADAMCHUK, V. I.; SIMBAHAN, G. C.; FERGUSON, R. B. Classification of crop yield variability in irrigated production fields. **Agronomy Journal**, Madison, v. 95, n. 1, p. 1105-1120, 2003.

DOERGE, T. A. **Management zones concepts**. Norcross: Potash & Phosphate Institute, 2000, 135 p.

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solo**. Rio de Janeiro: CNPSO, 2013, 412 p.

FARID, H. U.; BAKHSH, A.; AHMAD, N.; AHMAD, A.; MAHMOOD-KHAN, Z. Delineating site-specific management zones for precision agriculture. **Journal of Agricultural Science**, online, v. 154, n. 1, p. 273-286, 2016.

FRAISSE, C. W.; SUDDUTH, K. A.; KITCHEN, N. R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **Transactions of the ASAE**, v. 44, n. 1, p. 155-166, 2001.

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.

FU, Q.; WANG, Z.; JIANG, Q. Delineating soil nutrient management zones based on fuzzy clustering optimized by PSO. **Mathematical and Computer Modeling**, online, v. 51, n. 11-12, p. 1299-1305, 2010.

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, online, v. 127, n. 1, p. 302-310, 2016.

HEDLEY, C. The role of precision agriculture for improved nutrient management on farms. **Journal of the Science of Food and Agriculture**, v. 95, n. 1, p. 12-19, 2015.

ILIADIS, L. S.; VANGELOUDH, M.; SPARTALIS, S. An intelligent system employing an enhanced fuzzy C-Means clustering model: Application in the case of forest fires. **Computers and Electronics in Agriculture**, online, v. 70, n. 2, p. 276-284, 2010.

JAYNES, D. B.; COLVIN, T. S.; KASPAR, T. C. Identifying potential soybean management zones from multi-year yield data. **Computers and Electronics in Agriculture**, online, v. 46, n. 3, p. 309-327, 2005.

JAYNES, D. B.; KASPAR, T. C.; COLVIN, T. S.; JAMES, D. E. Cluster analysis of spatiotemporal corn yield patterns in an Iowa field. **Agronomy Journal**, Madison, v. 95, n. 3, p. 574-586, 2003.

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

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining Geostatistics**. New York, NY: The Blackburn Press, 1978. 600 p.

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

LARSCHEID, G.; BLACKMORE, B. S. **Interactions between farm managers and information systems with respect to yield mapping**. In P. C. Robert, R. H. Rust, W. E. Larson (Ed.), Precision Agriculture. WI: ASA, CSSA, SSSA, 1996. p. 1153-1163.

LI, Y.; SHI, Z.; LI, F.; LI, H. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, online, v. 56, n. 2, p. 174-186, 2007.

LI, Y.; SHI, Z.; WU, H.; LI, F.; LI, H. Definition of management zones for enhancing cultivated land conservation using combined spatial data. **Environmental Management**, online, v. 52, n. 4, p. 792-806, 2013.

MILLIGAN, G. W.; COOPER, M. C. A study of standardization of variables in cluster analysis. **Journal of Classification**, online, v. 5, n. 2, p. 181-204, 1988.

MINGOTI, S. A.; LIMA, J. O. Comparing SOM neural network with Fuzzy C-means, K-means and traditional hierarchical clustering algorithms. **European Journal of Operational Research**, online, v. 174, n. 3, p. 1742-1759, 2006.

MORAL, F. J.; TERRÓN, J. M.; SILVA, J. R. M. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. **Soil & Tillage Research**, online, v. 106, n. 2, p. 335-343, 2010.

ORTEGA R. A.; SANTIBÁÑEZ, O. A. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. **Computers and Electronics in Agriculture**, online, v. 58, n. 1, p. 49-59, 2007.

PEDROSO, M.; TAYLOR, J.; TISSEYRE, B.; CHARNOMORDIC, B.; GUILLAUME, S. A segmentation algorithm for the delineation of agricultural management zones. **Computers and Electronics in Agriculture**, online, v. 70, n. 1, p. 199-208, 2010.

PERALTA, N.; COSTA, J. L.; CASTRO, F.; BALZARINI, M. Delimitación de zonas de manejo con modelos de elevación digital y profundidad de suelo. **Interciencia**, online, v. 38, n. 6, p. 418-424, 2013.

PERALTA, N. R.; COSTA, J. L. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. **Computers and Electronics in Agriculture**, online, v. 99, n. 1, p. 218-226, 2013.

REICH, R. M.; CZAPLEWSKI, R. L.; BECHTOLD, W. A. Spatial cross-correlation of undisturbed, natural shortleaf pine stands in northern Georgia. **Environmental and Ecological Statistics**, online, v. 1, n. 3, p. 201-217, 1994.

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

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BIER, V. A.; BETZEK, N. M.; GAVIOLI, A. Data Interpolation in the definition of management zones. **Acta Scientiarum Technology**, Maringá, v. 38, n. 1, p. 31-40, 2016.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHEPERS, J. S.; JOHNSON, S. H.; LUCHIARI, A. Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. **Agronomy Journal**, Madison, v. 96, n. 1, p. 195-203, 2004.

SNEATH, P.H. A.; SOKAL, R. R. **Numerical taxonomy**. The principles and practice of numerical classification. San Francisco, CA: Freeman and Company, 1973. 549 p.

SOBJAK, R.; SOUZA, E. G.; BAZZI, C. L.; URIBE-OPAZO, M. A.; BETZEK, N. M. Redundant variables and the quality of management zones. **Engenharia Agrícola**, Jaboticabal, v. 36, n. 1, p. 78-93, 2016.

SUN, Y.; KANG, S.; LI, F.; ZHANG, L. Comparison of interpolation methods for depth to groundwater and its temporal and spatial variations in the Minqin oasis of northwest China. **Environmental Modelling & Software**, online, v. 24, n. 10, p. 1163-1170, 2009.

SWINDELL, J. E. G. Mapping the spatial variability in the yield potential of arable land through GIS analysis of sequential yield maps. In: STAFFORD, J. V. (Ed.). **Precision Agriculture**. Oxford: BIOS Scientific Publishes Ltd, 1997. p. 827-834.

TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. A. Management zones delineation using fuzzy clustering techniques in grapevines. **Precision Agriculture**, online, v. 14, n. 1, p. 18-39, 2013.

TILMAN, D.; BALZER, C.; HILL, J.; BEFORT, B. Global food demand and the sustainable intensification of agriculture. **Proceedings of the National Academy of Sciences**, Washington, v. 108, n. 50, p. 20260–20264, 2011.

VALENTE, D. S. M.; QUEIROZ, D. M.; PINTO, F. A. C.; SANTOS, N. T.; SANTOS, F. L. Definition of management zones in coffee production fields based on apparent soil electrical conductivity. **Scientia Agrícola**, Piracicaba, v. 69, n. 3, p. 173-179, 2012.

XIANG, L.; PAN, Y.; GE, Z.; ZHAO, C. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agriculture Sciences in China**, online, v. 6, n. 2, p. 180-188, 2007.

ZHANG, Z.; LÜ, X.; LV, N.; CHEN, J.; FENG, B.; LI, X. W.; MA, L. Defining agricultural management zones using Gis techniques: Case study of Drip-irrigated cotton fields. **Information Technology Journal**, online, v. 12, n. 21, p. 6241-6246, 2013.

6 ARTIGO 2:

UTILIZAÇÃO DA VARIÁVEL EXPERIÊNCIA DO PRODUTOR NA GERAÇÃO DE ZONAS DE MANEJO¹

RESUMO: No gerenciamento da variabilidade espacial das lavouras a abordagem baseada em zonas de manejo (ZMs) divide o talhão em sub-regiões, que apresentam topografia e condições do solo espacialmente homogêneas, de tal forma que tais ZMs devem conduzir aos mesmos resultados em potencial de rendimento das culturas. Os produtores têm conhecimento de quais áreas de um talhão apresentam altas e baixas produtividades e fazer uso dessa base de conhecimento pode permitir a identificação de ZMs em um campo com base no histórico de produção. O objetivo desse trabalho foi avaliar a eficiência de utilização da experiência do produtor na definição de ZMs. A pesquisa foi realizada em três áreas agrícolas localizadas na região Oeste do estado do Paraná/ Brasil e as ZMs foram geradas considerando-se três casos: a) Sem a utilização da variável experiência do produtor; b) Com a variável experiência do produtor e atributos estáveis do solo selecionados na etapa de seleção de variáveis; e c) Somente com a variável experiência do produtor. As ZMs geradas foram avaliadas pelos índices: Redução da Variância (VR), Índice de Desempenho Fuzzy (FPI), Índice da Partição da Entropia Modificada (MPE), Índice de Suavidade (SI) e Análise de Variância (ANOVA). O estudo mostrou que a utilização da experiência do produtor para definir ZMs pode ser uma ferramenta eficiente e simples, além de diminuir os custos no processo de definição de ZMs, quando comparado ao método tradicional de utilização de variáveis estáveis do solo e do relevo.

PALAVRAS-CHAVE: agricultura de precisão, agrupamento, conhecimento do produtor, unidades de manejo.

USE OF THE FARMER'S EXPERIENCE VARIABLE IN THE GENERATION OF MANAGEMENT ZONES

ABSTRACT: In the spatial variability management of fields, the approach based on management zones (MZs) divides the area into sub-regions, each with spatially homogenous topography and soil conditions, so that such MZs should lead to the same potential yields. Farmers have knowledge from experience of which areas of a field have large and low yields and making use of this knowledge base may allow the identification of MZs on a field based on the production history. The objective of this study was to evaluate the efficiency of using the farmer's experience in the definition of MZs. The study was conducted in three agricultural fields located in the West of the Paraná State in Brazil and the MZs were generated considering three cases: a) without using the variable farmer's experience; b) using the variable farmer's experience and stable soil properties selected in the variable selection stage; and c) only with the variable farmer's experience. The generated MZs were evaluated by the Variance Reduction (VR) index, Fuzziness Performance Index (FPI), Modified Partition Entropy (MPE), Smooth Index (SI) and Analysis of Variance (ANOVA). The study showed that the use of the farmer's experience to set MZs can be an efficient and simple tool, and can reduce costs in the MZs setting process when compared to the traditional method of using stable soil variables and the relief.

KEYWORDS: precision agriculture, clustering, farmer's knowledge, management units.

1. Introdução

A crescente preocupação com a aplicação mais eficiente de insumos agrícolas e com o aumento da capacidade produtiva dos solos faz com que aumente também a necessidade de entendimento da variabilidade espacial das áreas agrícolas. No gerenciamento da variabilidade espacial das lavouras, a abordagem baseada em zonas de manejo (ZMs) divide o talhão em sub-regiões, que apresentam topografia e condições do solo espacialmente homogêneas (FLEMING et al., 2004; MORAL et al., 2011; XIN-ZHONG et al., 2009), de tal forma que tais ZMs devem conduzir aos mesmos resultados em potencial de rendimento das culturas, permitindo uma taxa de entrada de nutrientes única dentro de cada sub-região (KITCHEN et al., 2005; SCHEPERS et al., 2004; MILNE et al., 2012; DIACONO et al., 2012).

Para Yao et al. (2014), a definição de ZMs possui outras aplicações além de representar áreas de mesmo potencial produtivo, como otimizar a grade de amostragem do solo, reduzindo o número de análises necessárias para o desenvolvimento dos mapas de aplicação de nutrientes e fertilizantes (LI et al., 2007). Tal metodologia permite ainda que sejam utilizados os equipamentos da agricultura convencional, já que a aplicação é constante dentro de cada zona e varia somente entre zonas.

No processo de geração das ZMs, métodos de agrupamento têm sido amplamente utilizados na literatura (TAYLOR et al., 2003; FRAISSE et al., 2001; LI et al., 2007; SCHENATTO et al., 2016; REYNIERS et al., 2006). O algoritmo Fuzzy C-Means (MORARI et al., 2009; XIN-ZHONG et al., 2009; BAZZI et al., 2013; MILNE et al., 2012; LI et al., 2007) é um método de agrupamento baseado na lógica fuzzy, definida por Zadeh (1965), que responde por incertezas associadas às fronteiras de classe e associação (DOBERMANN et al., 2003).

Os cientistas consideram que as experiências dos agricultores são importantes no desenvolvimento da agricultura como a conhecemos hoje (CROOKSTON, 1996). Para Fleming et al. (2004), se não fosse a experiência de tomada de decisão dos agricultores, grande parte da agricultura moderna seria desconhecida. Os produtores sabem quais áreas de um talhão apresentam grandes rendimentos e quais áreas que são de baixa produtividade, e é claro que as necessidades nutricionais são diferentes entre essas áreas. Fazer uso dessa base de conhecimento pode permitir a identificação de diferentes zonas de gestão em um campo com base no histórico de produção (FLEMING et al., 2000).

Para Morari et al. (2009), várias ferramentas podem ser utilizadas na obtenção de dados para a geração de ZMs e uma delas é a delimitação visual com base no conhecimento da área por parte do agricultor. Segundo Fleming et al. (2004), infelizmente, as contribuições potenciais do conhecimento do agricultor não estão sendo totalmente utilizadas. Já Hörbe et al. (2013) delinearam ZMs com base no conhecimento do agricultor e

classificaram uma área agrícola em zonas de alta, média e baixa performance na produtividade da cultura do milho, chegando ao número ideal de três ZMs e a análise de variância indicou heterogeneidade da fertilidade do solo entre as ZMs. Nkoka et al. (2014) implantou sistemas de irrigação em Moçambique que operam de acordo com o contexto específico de cada área e cada sistema exibe um padrão único de gestão, baseados no histórico que o agricultor tem da área. Fleming et al. (2004) comparou mapas de prescrição desenvolvidos a partir da experiência do produtor com mapas de prescrição desenvolvidos a partir de análises da fertilidade do solo, em duas áreas de milho no Colorado, e os resultados da análise de variância foram semelhantes ao comparar os dois métodos. Khosla et al. (2002) também gerou ZMs utilizando a cor do solo obtida por meio de imagens áreas, topografia e a experiência dos agricultores no histórico de rendimento da área e concluiu que o tratamento baseado nas ZMs permitiu gerenciar melhor a variabilidade do campo do que tratamentos convencionais.

Nesse contexto, o objetivo desse trabalho foi avaliar a eficiência de utilização da experiência do produtor na definição de zonas de manejo.

6.2 Material e métodos

A pesquisa foi realizada em três áreas agrícolas comerciais: A primeira área (chamada de área A) possui cerca de 15,5 ha (Figura 1a) e está localizada no município de Céu Azul - PR, com localização geográfica central aproximada de 25°06'32" S e 53°49'55" O e elevação média de 620 m. A segunda área (área B) possui 20,9 ha (Figura 1b) e está localizada no município de Serranópolis do Iguaçu - PR, sob coordenadas geográficas centrais aproximadas de 25°40'48" S e 54°00'53" O e com elevação média de 355 m. A terceira área (área C) possui aproximadamente 9,9 ha (Figura 1c) e está localizada no município de Serranópolis do Iguaçu - PR, sob coordenadas geográficas centrais aproximadas de 25°24'28" S e 54°00'17" O e com elevação média de 355 m.

O solo das áreas em estudo foi classificado como LATOSSOLO VERMELHO Distroférico (EMBRAPA, 2013) e vem sendo cultivado sob sistema de plantio direto com sequência de culturas soja, trigo, milho e aveia na área A e sucessão de soja e milho nas áreas B e C. Foram definidas grades amostrais irregulares, levando em conta uma linha central imaginária entre as curvas de nível de cada área. A fim de satisfazer as restrições da análise geoestatística (JOURNEL; HUIJBREGTS, 1978) quanto ao número mínimo de pares para cálculo das semivariâncias do semivariograma, foi utilizada uma malha de amostragem densa com 2,58 pontos ha⁻¹ na área A, 3,07 pontos ha⁻¹ para a área B e 4,24 pontos ha⁻¹ para a área C.

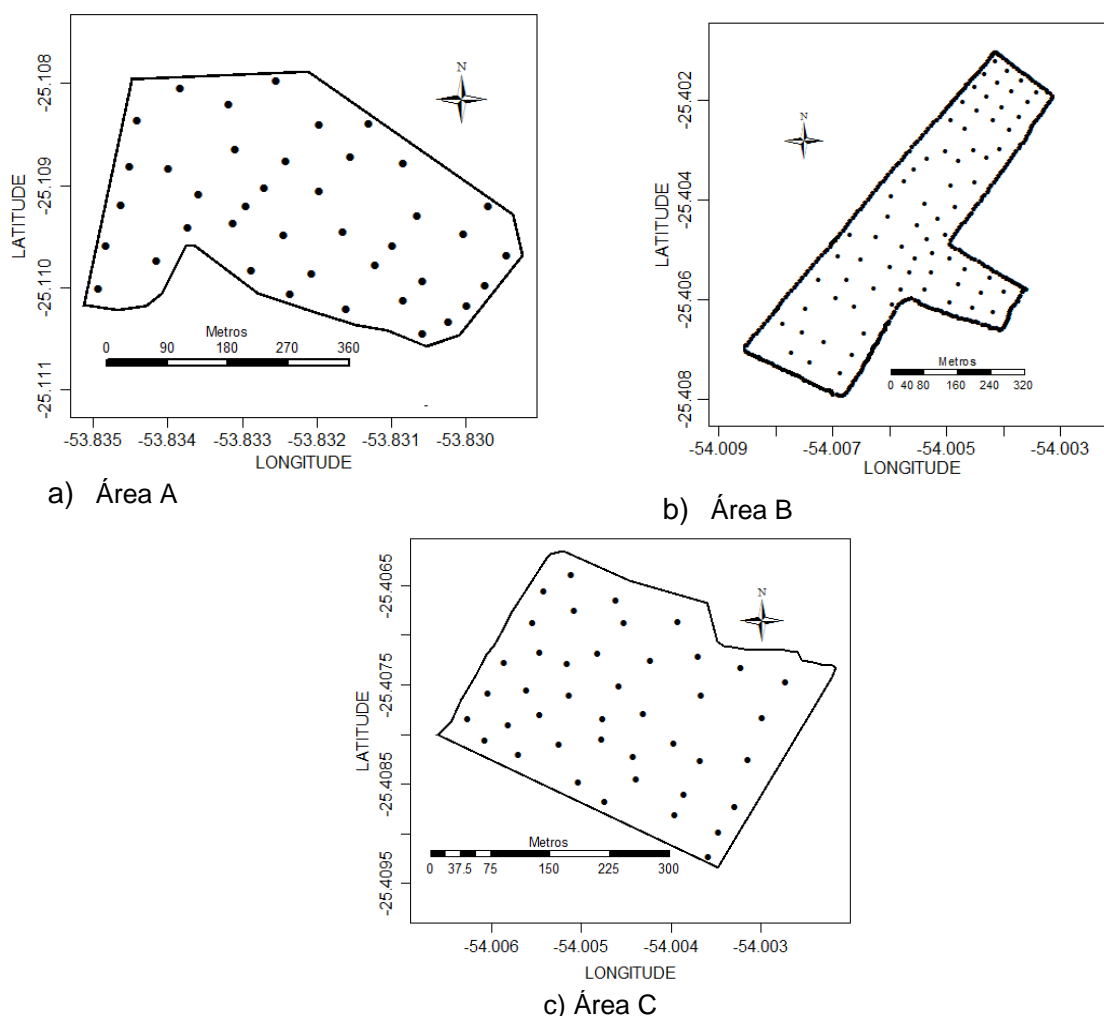


Figura 1 Áreas experimentais e pontos amostrais.

Para a definição das ZMs, foram utilizadas variáveis consideradas estáveis; por isso, foram excluídos os atributos químicos do solo, com base na recomendação geral de Doerge (2000). A elevação foi determinada com uma estação eletrônica Topcon GPT-7505. Já a resistência do solo a penetração (RSP) foi determinada com um penetrógrafo Falker PGL 1020 e, posteriormente, calculada a média para cada profundidade 0-0,1m, 0,1-0,2m, 0,2-0,3m, para cada um dos quatro anos em estudo. As amostras de solo foram coletadas na profundidade de 0-0,2m e enviadas ao laboratório para análise dos atributos químicos e texturais do solo.

Os dados de produtividade da soja para a área A foram determinados com um monitor de colheita CASE AFS PRO 600 acoplado a uma colhedora Case 2388. Para as áreas B e C, a produtividade da soja e do milho foram determinadas por colheita de uma amostra de 1 m² em cada um dos pontos de amostragem. Em todos os casos, o rendimento foi corrigido para o teor de água de 13%. Para atender à exigência de estabilidade de dados de produção, que é fortemente influenciada pelo clima e pelas chuvas, os dados de produtividade de quatro anos agrícolas (2012, 2013, 2014 e 2015) foram normalizados para gerar uma única variável para o atributo produtividade em cada área.

A experiência do produtor foi coletada por meio de uma visita a cada propriedade, em que o produtor dividiu o talhão em três classes (alta, média e baixa) de produtividade, baseado na experiência de anos anteriores de cultivo da área. Foi solicitado então ao produtor que estimasse a produtividade média para cada uma das três classes, criando-se, assim, a variável numérica experiência do produtor.

A fim de avaliar a correlação espacial entre os atributos analisados, foi utilizada a correlação espacial bivariada de Moran (CZAPLEWSKI; REICH, 1993), podendo-se verificar quais atributos influenciaram de forma positiva ou negativa a produtividade. Após gerada a matriz de correlação espacial, as variáveis a serem utilizadas na geração das ZMs foram selecionadas por meio do método de seleção de variáveis proposto por Bazzi et al. (2013): (a) eliminação de variáveis sem correlação espacial significativa a 95% de significância; (b) remoção das variáveis que não possuem correlação com a produtividade; (c) ordenação das demais variáveis em módulo, considerando-se o grau de correlação com a produtividade; e (d) eliminação de variáveis que são correlacionados umas com as outras, dando preferência para a retirada das variáveis com menor correlação com a produtividade.

Na análise geostatística das variáveis (atributos) selecionadas, foram ajustados ao semivariograma experimental os modelos esférico, exponencial e gaussiano, e o melhor modelo foi determinado por meio da estatística de validação cruzada (SUN et al., 2009; ARSLAN, 2012). Os dados foram interpolados por krigagem ordinária, a fim de criar uma grade de 5 x 5 m, com maior detalhamento dos atributos, que, conforme apresentado por SCHENATTO et al. (2016), é o melhor método de interpolação para geração do grid amostral antes do processo de geração das ZMs.

Como as variáveis a serem utilizadas no processo de agrupamento podem estar em diferentes unidades de medida, é recomendando que se normalize os dados antes de gerar as ZMs, pois os algoritmos de agrupamento são sensíveis à escala de valores das variáveis de entrada. Para normalizar os dados foi utilizado o método da amplitude (Equação 1) (MIEKLE; BERRY, 2007).

$$P_{iN} = \frac{(P_i - \text{Mediana})}{\text{Amplitude}} \quad \text{Eq. (1)}$$

em que, P_{iN} - pixel i normalizado; P_i - pixel i a ser normalizado.

Com as variáveis selecionadas na matriz de correlação e a variável experiência do produtor, foram geradas as ZMs em cada área utilizando o método de agrupamento Fuzzy C-Means, considerando-se três casos: a) Sem a utilização da variável experiência do produtor; b) Com a variável experiência do produtor e atributos estáveis do solo selecionados na etapa de seleção de variáveis; e c) Somente com a variável experiência do produtor, considerando duas, três e quatro sub-regiões.

É importante diferenciar nomenclaturas (termos) utilizadas neste texto. De acordo com Pedroso et al. (2010), zonas de manejo (ZMs) são áreas espacialmente contíguas à qual um determinado tratamento pode ser aplicado; uma classe de administração pode consistir em mais do que uma zona de manejo, isto é, toda a área em que o mesmo tratamento pode ser aplicado.

As ZMs geradas foram avaliadas quantitativamente pelos seguintes índices:

1) Redução da Variância (VR) (DOBERMANN et al., 2003; XIANG et al., 2007) - Equação 2: Este índice foi utilizado para a variável produtividade média normalizada, com a expectativa que a soma das variâncias dos dados de cada zona de manejo seja menor que a variância total.

$$RV = 1 - \frac{\sum_{i=1}^c (W_i * V_{um_i})}{V_{\acute{a}rea}} * 100 \quad \text{Eq. (2)}$$

em que, c - número de zonas de manejo; W_i - proporção da área em cada zona de manejo; V_{um_i} - variância dos dados de cada zona de manejo; $V_{\acute{a}rea}$ - variância da amostra dos dados para toda a área.

2) Índice de Desempenho Fuzzy (Fuzziness Performance Index (FPI)), Equação 3: Permite determinar o grau de separação (isto é, confusão) entre os c -clusters fuzzy de um conjunto de dados X . Quando os valores de FPI se aproximam de 0 indicam classes distintas, apresentando pequeno grau de compartilhamento dos membros (dados) entre elas, enquanto que valores próximos a 1 indicam não haver classes distintas, apresentando elevado grau de compartilhamento dos membros entre as classes (FRIDGEN et al., 2004).

$$FPI = 1 - \frac{c}{(c-1)} \left[1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad \text{Eq. (3)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elemento ij da matriz de pertinência fuzzy.

3) Índice da Partição da Entropia Modificada (Modified Partition Entropy (MPE)), Equação 4: Esse índice estima a quantidade de desorganização criada por um número específico de clusters. Valores de MPE próximos de 1 indicam que predomina a desorganização, enquanto que valores se aproximando de 0 indicam melhor organização (BOYDELL; MCBRATNEY, 2002).

$$MPE = \frac{- \sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) / n}{\log c} \quad \text{Eq. (4)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elementos ij da matriz de pertinência fuzzy.

4) Índice de Suavidade (Smooth Index (IS)), Equação 5: Calcula a frequência de mudança das classes do mapa temático nas direções horizontal, vertical e das diagonais, pixel a pixel. Na hipótese de que o mapa possuísse uma área totalmente homogênea, resultaria um índice de suavidade igual a 100%, devido à ausência de mudanças de classe. Da mesma forma, se o mapa fosse completamente gerado com valores aleatórios, o índice de suavidade apresentaria um valor próximo a zero.

$$SI = 100 - \left(\left(\frac{\sum_{i=1}^k NM_{Hi}}{4P_H} + \frac{\sum_{j=1}^k NM_{Vj}}{4P_V} + \frac{\sum_{l=1}^k NM_{Ddl}}{4P_{Dd}} + \frac{\sum_{m=1}^k NM_{Dem}}{4P_{De}} \right) * 100 \right) \quad \text{Eq. (5)}$$

em que, NM_{Hi} - número de mudanças na linha i (horizontal); NM_{Vj} - número de mudanças na coluna j (vertical); NM_{Ddl} - número de mudanças na diagonal l (diagonal direita - Dd); NM_{Dem} - número de mudanças na diagonal m (diagonal esquerda - De); k - número máximo de pixels na linha, coluna ou diagonais; P_H - possibilidade de mudanças de pixels na horizontal; P_V - possibilidade de mudanças de pixels na vertical; P_{Dd} - possibilidade de mudanças na diagonal direita - Dd ; P_{De} - possibilidade de mudanças na diagonal esquerda - De .

5) Análise de Variância (ANOVA): os valores de produtividade foram comparados entre as ZMs usando a produtividade média normalizada, e o teste de comparação de média de Tukey foi realizado para identificar se as sub-regiões geradas apresentaram diferenças significativas na produtividade média normalizada (admitindo que não houve dependência espacial dentro de cada ZM).

6.3 Resultados e discussão

De acordo com os critérios de seleção de variáveis utilizando-se a correlação espacial bivariada de Moran, as variáveis selecionadas para a área A foram elevação e RSP 0-0.1 m e, nas áreas B e C, apenas a elevação foi selecionada (Tabela 1). O atributo elevação foi selecionado para definição das ZMs para as três áreas, concordando com os resultados encontrados por diversos autores, como Jaynes et al. (2005), Schenatto et al. (2016), Bazzi et al. (2015), Fraisse et al. 2001, Schepers et al. (2004) e Peralta e Costa (2013), o que significa que, quando a área não é plana, a variável elevação frequentemente apresenta associação espacial com a produtividade da cultura.

Tabela 1 Esquema de seleção e eliminação de variáveis (atributos) para definição de zonas de manejo

Atributos	Área A	Área B	Área C
RSP 0,0 – 0,1 m (MPa)	X	X	X
RSP 0,1 – 0,2 m (MPa)	X	X	X
RSP 0,2 – 0,3 m (MPa)	X	X	X
Elevação (m)	X	X	X
Declividade (°)	X	X	X
Areia (%)	X	X	X
Silte (%)	X	X	X
Argila (%)	X	X	X
MO (%)	X	X	X

[] - Eliminados por não apresentarem autocorrelação espacial; [] - Eliminados por não apresentarem correlação espacial com a produtividade; [] - Eliminados por serem redundantes (possuírem correlação com algum atributo que possui maior correlação com a produtividade); [] - Selecionadas para geração das ZMs. Nível de significância dos testes: 0,05.

As variáveis estáveis do solo selecionadas nas áreas A, B e C por meio da matriz de correlação espacial bivariada de Moran e a variável experiência do produtor foram normalizadas pelo método da amplitude e posteriormente interpoladas por krigagem ordinária (Figuras 2, 3 e 4) e, então, importadas para o SDUM (Software para Definição de Unidades de Manejo) para a definição das ZMs. Os mapas temáticos das variáveis do solo e da produtividade foram divididos em duas, três e quatro classes, enquanto que o mapa da variável experiência do produtor, a pedido, foi dividido pelo produtor em três classes.

Foram definidas para as três áreas experimentais ZMs com duas, três e quatro classes (Figura 2, 3, e 4), utilizando-se três combinações de variáveis: a) somente variáveis estáveis do solo, isto é, sem a variável experiência do produtor (SEM), b) com variável experiência do produtor e variáveis estáveis do solo (COM) e c) somente a variável experiência do produtor (SOMENTE).

Foi possível verificar que a utilização da variável experiência do produtor com os atributos estáveis do solo (COM) permitiu a apresentação de ZMs mais suaves e bem definidas, facilitando a operacionalização das áreas. Pequenas variações nos níveis das variáveis analisadas possíveis de verificar nos mapas temáticos (Figura 2, 3 e 4) foram suavizadas nas ZMs após o processo de agrupamento.

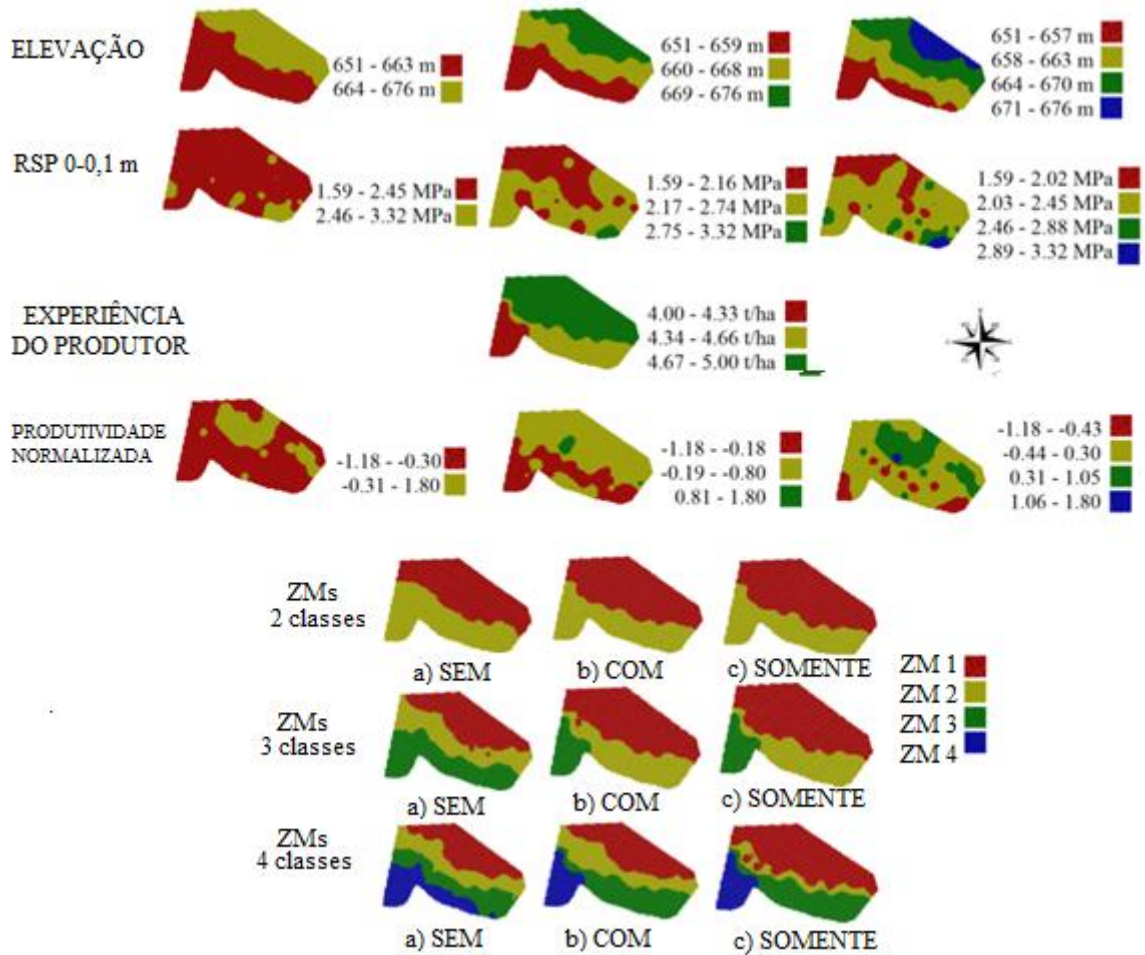


Figura 2 Mapas temáticos dos atributos do solo (elevação e RSP 0-0,1) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área A e as zonas de manejo geradas sem a variável experiência do produtor (SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE).

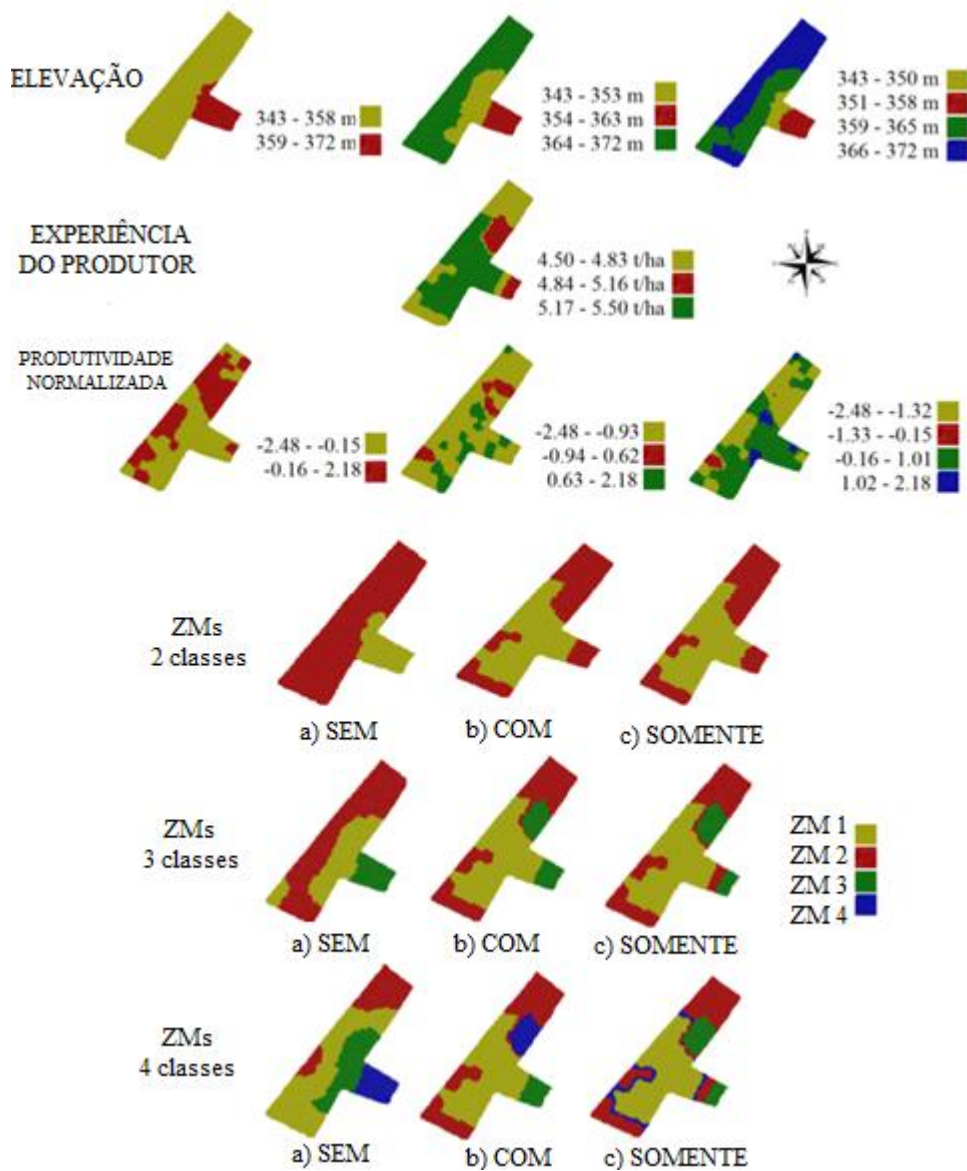


Figura 3 Mapas temáticos dos atributos do solo (elevação) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área B e as zonas de manejo geradas sem a variável experiência do produtor (SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE).

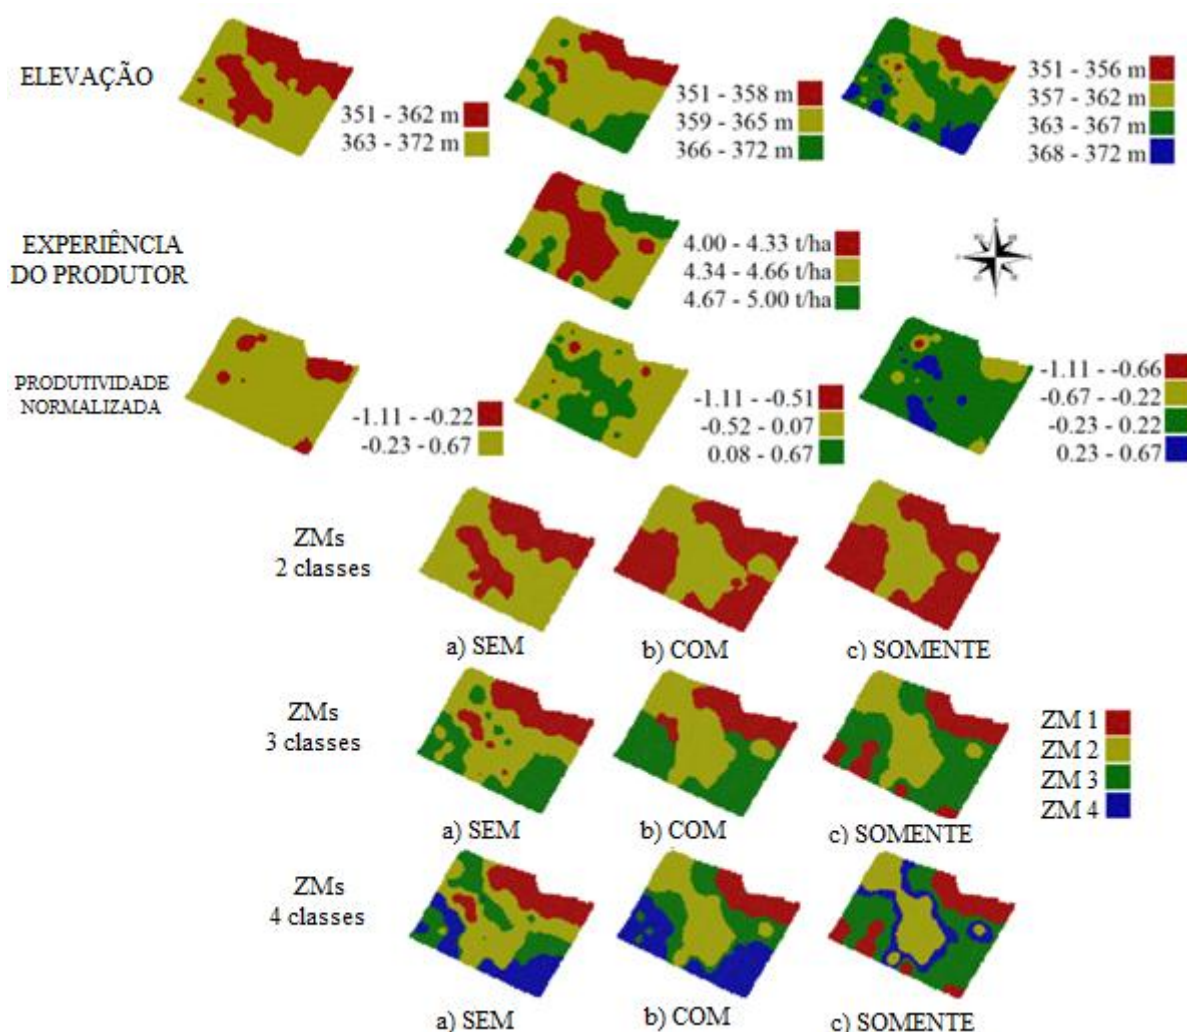


Figura 4 Mapas temáticos dos atributos do solo (elevação) utilizados na geração das zonas de manejo, variável experiência do produtor e produtividade média normalizada de quatro anos agrícolas (2012, 2013, 2014 e 2015) para a área C e as zonas de manejo geradas sem a variável experiência do produtor (SEM), com a experiência do produtor (COM) e somente com o uso dessa variável (SOMENTE)

Por meio da ANOVA (Tabela 2) foi possível testar se as médias de produtividade média normalizada foram estatisticamente diferentes entre as classes. Encontraram-se diferenças significativas quando a divisão foi realizada em dois, três e quatro classes para as áreas A e B, enquanto que para a área C não foi possível encontrar classes com produtividade estatisticamente distintas. Os resultados da ANOVA podem ser confirmados por meio dos gráficos de boxplot dos dados de produtividade após gerada a divisão com duas, três e quatro classes (Figuras 5, 6 e 7). Na área C, onde através da ANOVA (teste de Tukey) não foi possível identificar zonas de manejo com produtividades distintas, isso possivelmente ocorreu devido à homogeneidade dos dados de produtividade (Figura 7) para esta área.

Os valores de VR, FPI, MPE e IS fornecidos por cada abordagem avaliada com duas, três e quatro classes estão apresentados nas Tabela 2 e Figura 8. Para a área A verificou-se que houve maior redução da variância (VR) quando a área foi dividida em duas classes e utilizadas somente as variáveis estáveis do solo (elevação e RSP 0-0,1 m) na

geração das classes (VR=42,5%). Entretanto, quando a área foi dividida em quatro classes com somente a variável experiência do produtor foi obtido um VR=42%. Para a área B, a divisão que apresentou melhores resultados para VR foi a divisão em três classes com somente a variável experiência do produtor (VR=44%). Na área C, o melhor VR foi obtido com a utilização de somente a experiência do produtor na divisão com quatro classes (VR=92%).

Os menores valores de FPI (maior grau de separação entre os agrupamentos), em todas as áreas, foram obtidos quando a divisão foi realizada em três classes e com somente a variável experiência do produtor. Essa mesma divisão também apresentou os menores MPE (melhor organização dos agrupamentos), embora outras divisões também tenham apresentado o mesmo desempenho.

Com relação à suavidade das curvas de contorno que definem as zonas de manejo, avaliadas pelo índice IS%, obteve-se o melhor desempenho com a divisão em duas classes, em todas as áreas. Quando as áreas foram divididas em duas classes, o índice de suavidade obtido para a área A foi igual para as três combinações de variáveis testadas. Na área B se mostrou mais satisfatório quando utilizados somente os atributos estáveis do solo. Já para a área C o melhor IS foi quando utilizada somente a variável experiência do produtor. Com três classes, os melhores resultados de IS foram obtidos quando utilizou-se somente a variável experiência do produtor para a área A; para a área B, os melhores resultados foram obtidos sem a variável experiência do produtor; e na área C com a variável experiência do produtor e variáveis estáveis do solo. Com quatro classes, os melhores resultados de IS para as três áreas em estudo foram encontrados quando utilizados a variável experiência do produtor e atributos estáveis do solo. Porém, os valores de IS variaram para todos os casos em menos de 5%, podendo afirmar que não houve uma diferença significativa na suavidade dos mapas quando comparadas as diferentes combinações de variáveis e o número de classes.

Outra avaliação útil na escolha do número de variáveis a serem utilizadas é que o número de zonas criadas seja igual ou pouco maior que o número de classes. Isto significa que o número de zonas menos o número de classes (ZM-C) deveria ser idealmente zero. Os melhores resultados foram encontrados com duas classes, pois apresentou um valor menor dessa variável para as três áreas em estudo. Os piores resultados, ou seja, a classificação que gerou um maior valor de ZM-C foram: Área A: ZMs geradas com quatro classes e somente a variável experiência do produtor; Área B: com três classes e somente a variável experiência do produtor e Área C: somente com atributos estáveis com três classes.

Tabela 2 Índices de avaliação calculados considerando a geração de ZMs sem a adição da variável experiência do produtor (somente com atributos estáveis selecionados na matriz de correlação), com variável experiência do produtor e atributos estáveis do solo selecionados na matriz de correlação e somente com a variável experiência do produtor

Área	C	Atributos	ANOVA*				VR%	FPI	MPE	IS%	ZMs	ZM-C	
			1	2	3	4							
A	2	Sem experiência do produtor	a	b			42,5	0,10	0,02	98,5	2	0	
		Com experiência do produtor	a	b			25,4	0,07	0,02	98,5	2	0	
		Somente experiência do produtor	a	b			25,4	0,05	0,01	98,5	2	0	
	3	Sem experiência do produtor	a	a	b		23,7	0,19	0,04	96,7	4	1	
		Com experiência do produtor	a	a	b		30,1	0,11	0,02	97,8	3	0	
		Somente experiência do produtor	a	b	b		23,7	0,03	0,01	97,9	3	0	
	4	Sem experiência do produtor	a	a	b	b	34,2	0,29	0,05	95,4	6	2	
		Com experiência do produtor	a	ac	b	b c	23,7	0,18	0,04	96,5	4	0	
		Somente experiência do produtor	a	a	b	b	41,5	0,06	0,01	95,6	7	3	
	B	2	Sem experiência do produtor	a	b			3,9	0,06	0,01	99,3	2	0
			Com experiência do produtor	a	b			8,3	0,09	0,02	97,9	5	3
			Somente experiência do produtor	a	b			8,3	0,04	0,01	97,9	5	3
3		Sem experiência do produtor	a	b	b		11,5	0,66	0,12	97,9	4	1	
		Com experiência do produtor	a	b	a		8,3	0,10	0,02	97,12	6	3	
		Somente experiência do produtor	a	b	c		44,4	0,03	0,01	96,9	8	5	
4		Sem experiência do produtor	a	a	b	b	6,5	0,74	0,15	97,5	5	1	
		Com experiência do produtor	a	bc	ac	d	19,4	0,09	0,02	97,1	6	2	
		Somente experiência do produtor	a	bd	ad	c	19,4	0,03	0,01	95	7	3	
C		2	Sem experiência do produtor	a	a			1	0,13	0,03	95,8	3	1
			Com experiência do produtor	a	a			8,7	0,23	0,04	95,7	5	3
			Somente experiência do produtor	a	a			5,3	0,09	0,02	96,3	3	1
	3	Sem experiência do produtor	a	a	a		11,5	0,20	0,04	92,7	14	11	
		Com experiência do produtor	a	a	a		3,1	0,18	0,04	95,4	6	3	
		Somente experiência do produtor	a	a	a		0	0,07	0,02	93,6	9	6	
	4	Sem experiência do produtor	a	a	a	a	17,4	0,23	0,05	90,7	14	10	
		Com experiência do produtor	a	a	a	a	4,8	0,22	0,05	92,4	11	7	
		Somente experiência do produtor	a	ab	ac	-	91,9	0,10	0,02	89,8	12	8	

* Teste de Tukey com 95% de significância. C - Número de Classes; VR - Redução da Variância; FPI - Índice de Desempenho Fuzzy; MPE - Índice de Partição da Entropia Modificada; IS - Índice de Suavidade; ZMs - Número de zonas; ZM - C: Número de zonas - Número de Classes

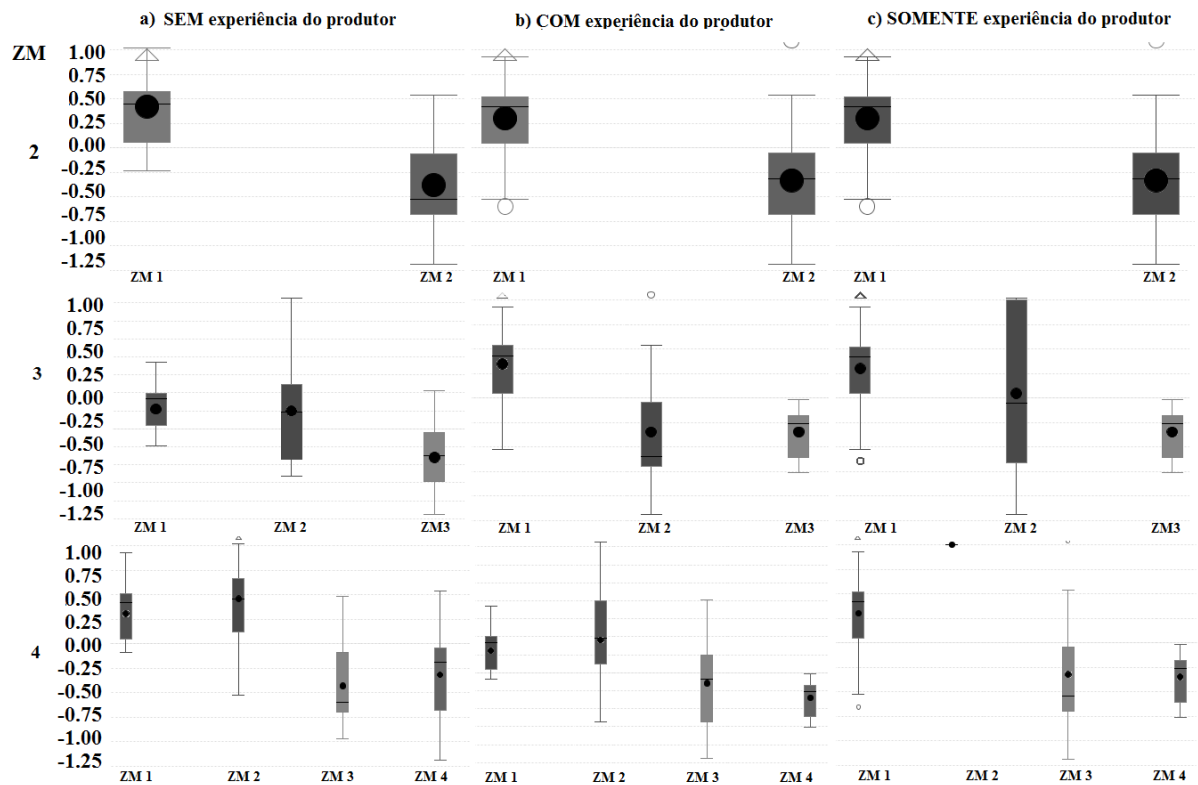


Figura 5 Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para a área A.




Figura 6 Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para a área B.

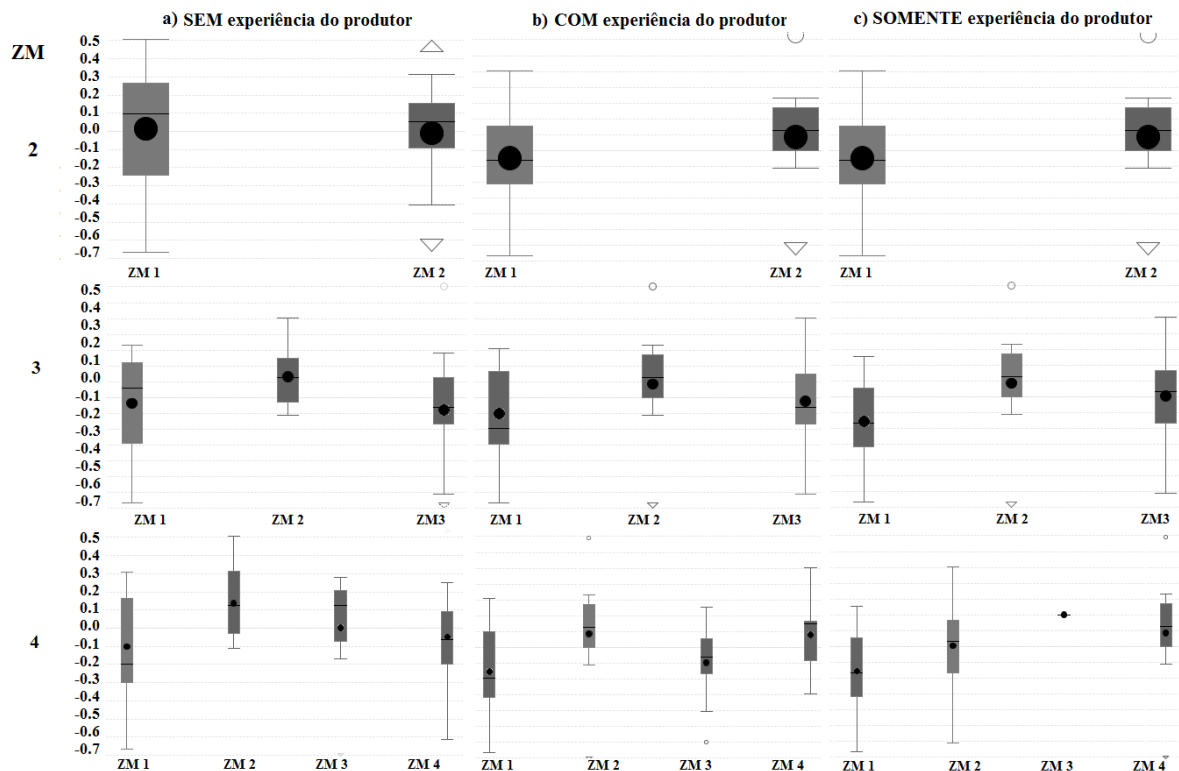


Figura 7 Gráficos boxplot dos dados de produtividade média normalizada divididos em duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor para a área C.

Nessas condições, todas as três combinações de variáveis (atributos estáveis do solo e experiência do produtor) permitiram definir ZMs expressivas. Os índices de avaliação utilizados (Tabela 2 e Figura 8) acusaram resultados mais satisfatórios para a abordagem utilizando somente a variável experiência do produtor com três classes de manejo para as três áreas pesquisadas. Entretanto, a maioria dos índices avaliados apresentaram valores muito próximos para as três combinações de variáveis utilizadas.

Foi identificada, então, a importância da variável experiência do produtor na definição de ZMs, podendo ser uma abordagem econômica e simplificada para a geração de ZMs para otimização de amostragem do solo e variação de determinadas operações de manejo e plantio quando o produtor possui anos de experiência no cultivo da área, concordando com os resultados obtidos por Fleming et al. (2004), Khosla et al. (2002) e Hörbe et al. (2013), que também encontraram resultados satisfatórios na utilização do conhecimento empírico do produtor para definir ZMs.

Vale ressaltar que quando o produtor sugere um número específico de classes, (nesse estudo foi realizada a divisão da variável experiência do produtor pelo proprietário em três classes), a divisão em mais classes (quatro ou cinco classes) não tem aplicação prática, e, como comprovado pelos índices de desempenho, não apresentam resultados satisfatórios.

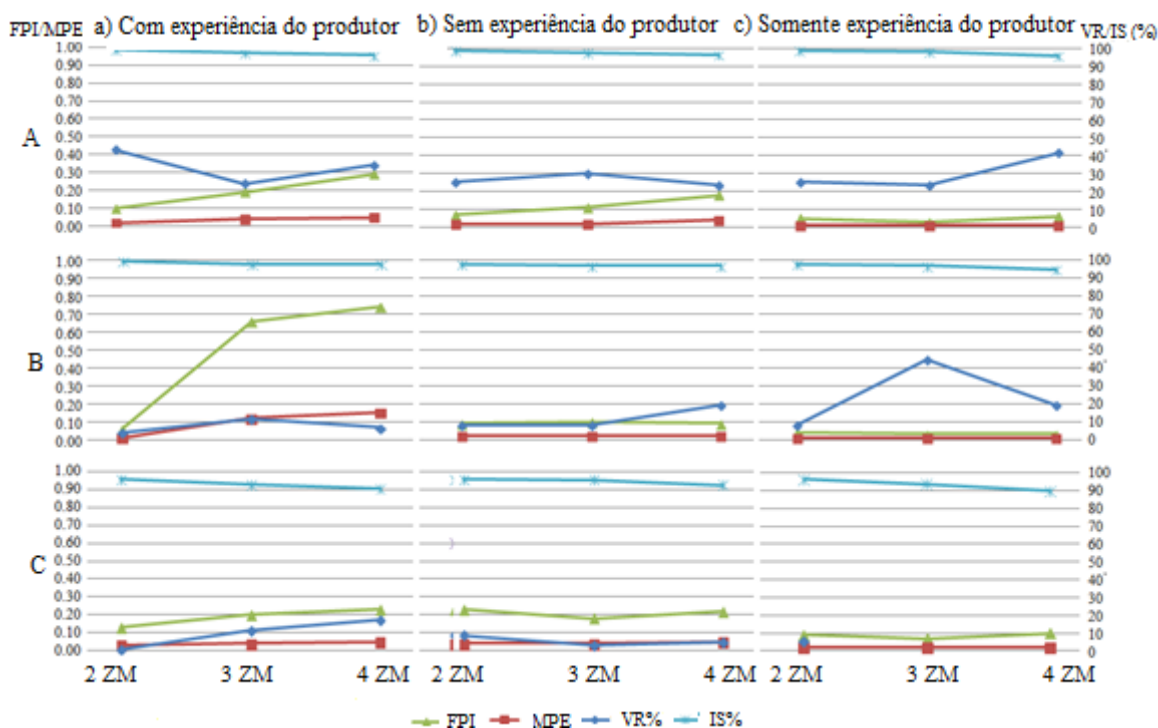


Figura 8 Índices FPI, MPE, VR% e IS para as três abordagens avaliadas, considerando dois, três e quatro classes.

Outro fator importante é a verificação se as ZMs apresentaram diferenças significativas para outros atributos. Foi realizada a análise pelo teste de comparação de médias de Tukey (ANOVA, Tabela 3) das ZMs geradas com atributos texturais do solo (argila, silte e areia), químicos (pH, Al, Ca, C, Cu, Fe, P, H+Al, Mg, Mn, K, Zn), matéria orgânica, atributos físicos (Resistência do Solo a Penetração, densidade, macroporosidade, microporosidade, porosidade total, Umidade) e elevação. A ordem de apresentação das variáveis está de acordo com sua relevância no teste de Tukey.

Verificou-se que os atributos que apresentaram maiores diferenças significativas foram elevação, produtividade, RSP 0-0,1 m, areia, Carbono, Cobre, Matéria Orgânica e RSP 0,1-0,2 m, sendo que, destes, a elevação e a RSP 0-0,1 m foram atributos utilizados na geração das ZMs. Vale ressaltar que os macronutrientes P e K também apresentaram frequentemente diferenças significativas.

Os casos em que as ZMs foram geradas sem a variável experiência do produtor e com essa variável foram os que apresentaram melhores diferenças significativas dos atributos do solo avaliados, sendo que a divisão em duas classes foi a que apresentou mais diferenças significativas dos valores dos atributos no solo.

Ressalta-se que os bons resultados obtidos com a variável experiência do produtor nas áreas pesquisadas podem ter sido influenciados positivamente devido aos produtores entrevistados terem conhecimento das suas áreas por longo tempo. A representatividade dessa variável pode ser reduzida em áreas com pouca experiência de cultivo pelo produtor e também com o aumento da área em análise, pois em áreas maiores o produtor

possivelmente não consegue realizar tal gerenciamento da área, sendo, assim, uma solução para pequenos produtores e uma alternativa de baixo custo.

Tabela 3 Anova (Teste de Tukey) para os atributos do solo nas áreas A, B e C em relação às ZMs geradas com duas, três e quatro classes SEM experiência do produtor, COM experiência do produtor e SOMENTE experiência do produtor

Área	A									B									C											
	2			3			4			2			3			4			2			3			4					
Nº Classes	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O	S	C	O
Elevação	**	**	**	**	*	*	*	*	*	**	**	*	**	**	*	**	**	*	**	**	*	**	**	*	**	**	*	**	**	*
Prod	**	**	**	*	*	*	*	*	*	**	**	**	*	*	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
RSP 0,0-0,1	**	**	**	*	*	*	*	*	*	**	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
Areia	**	**	**	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
C										**	**	*	*	*	*	*	*	*	**	**	*	*	*	*	*	*	*	*	*	*
Cu	**	**	**	*	*	*	*	*	*	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
M.O.										**	**	*	*	*	*	*	*	*	**	**	*	*	*	*	*	*	*	*	*	*
RSP 0,1-0,2				*	*	*	*	*	*	**	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
H+Al	**			*	*	*										*	*	*	**	**	*	*	*	*	*	*	*	*	*	*
Micro							*	*	*	**	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
RSP 0,2-0,3				*	*	*	*	*	*	**	**	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
P				*			*	*	*	*	*	*							**	**	*	*	*	*	*	*	*	*	*	*
Argila				*	*	*	*	*	*	*	*	*							**	*	*	*	*	*	*	*	*	*	*	*
K							*			**	*	*	**	*	*	*	*	*										*	*	*
Mn				*	*	*	*	*	*	*	*	*				*	*	*				*	*	*				*	*	*
Densidade							*			**	**	*	*	*	*	*	*	*												
pH	**			*												*		*	**	*	*	*	*	*						
Zn										**	*	*	*	*	*	*	*	*				*	*	*				*	*	*
PT							*			**	*	*	*	*	*	*	*	*												
Fe										**	*	*	*	*	*	*	*	*										*	*	*
Al																			**	*	*	*	*	*				*	*	*
Macro							*			**	*	*																*	*	*
Silte				*	*	*													*	*	*							*	*	*
Umidade							*						*	*	*	*	*	*												
Ca													*	*	*	*	*	*										*	*	*
Decl.							*									*	*	*												
Mg																														

S – Sem variável experiência do produtor; C – Com variável experiência do produtor; O – Somente variável experiência do produtor; ** - Diferença significativa entre as médias de todas as classes a 95% de significância; * - Diferença significativa entre pelo menos duas classes a 95% de significância. Decl: Declividade; Prod: Produtividade.

6.4 Conclusões

Nesse estudo conclui-se que a utilização da experiência do produtor para definir ZMs pode ser uma ferramenta eficiente e simples, além de diminuir os custos no processo de definição de ZMs, quando comparado ao método tradicional de utilização de variáveis estáveis do solo e do relevo.

Segundo os índices avaliados, a divisão que apresentou melhores resultados foi a abordagem utilizando somente a variável experiência do produtor com três classes de manejo, porém a Anova mostrou maiores diferenças significativas dos atributos do solo quando as ZMs foram geradas com a utilização das variáveis estáveis do solo e do relevo.

6.5 Referências

ARSLAN, H. Spatial and temporal mapping of groundwater salinity using ordinary kriging and indicator kriging: The case of Bafra Plain, Turkey. **Agriculture Water Management**, online, v. 113, n. 1, p. 57-63, 2012.

BAZZI, C. L.; SOUZA, E. G.; URIBE-OPAZO, M. A.; NÓBREGA, L.H. P.; ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, Jaboticabal, v. 33, n. 5, p. 952-964, 2013.

BAZZI, C. L.; SOUZA, E. G.; KONOPATZKI, M. R.; NÓBREGA, L. H. P.; URIBE-OPAZO, M. A. Management zones applied to pear orchard. **International Journal of Food Agriculture and Environment**, online, v. 13, n. 1, p. 86-92, 2015.

BOYDELL, B.; MCBRATNEY, A. B. Identifying potential within-field management zones from cotton yield estimates. **Precision Agriculture**, online, v. 3, n. 1, p. 9-23, 2002.

CROOKSTON, R. K. **Using decision cases to enhance technology transfer in precision agriculture**. Minneapolis: American Society of Agronomy, 1996. 1219 p.

CZAPLEWSKI, R. L.; REICH, R. M. **Expected value and variance of Moran's bivariate spatial autocorrelation statistic under permutation**. Fort Collins: Research Paper, 1993. 13 p.

DIACONO, M.; CASTRIGNANÒ, A.; TROCCOLI, A.; BENEDETTO, D.; BASSO, B.; RUBINO, P. Spatial and temporal variability of wheat grain yield and quality in a Mediterranean environment: A multivariate geostatistical approach. **Field Crops Research**, online, v. 131, n. 1, p. 49-62, 2012.

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

DOERGE, T. A. **Management zones concepts**. Norcross: Potash & Phosphate Institute, 2000, 135 p.

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solo**. Rio de Janeiro: CNPSO, 2013, 412 p.

FLEMING, K. L.; HEERMANN, D. F.; WESTFALL, D. G. Evaluating Soil Color with Farmer Input and Apparent Soil Electrical Conductivity for Management Zone Delineation. **Agronomy Journal**, Madison, v. 96, n. 1, p. 1581-1587, 2004.

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

FRAISSE, C. W.; SUDDUTH, K. A.; KITCHEN, N. R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **Transactions of the ASAE**, online, v. 44, n. 1, p. 155-166, 2001.

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.

HÖRBE, T. A. N.; AMADO, T. J. C.; FERREIRA, A. O.; ALBA, P. J. Optimization of corn plant population according to management zones in Southern Brazil. **Precision Agriculture**, online, v. 14, n. 4, p. 450-465, 2013.

JAYNES, D. B.; COLVIN, T. S.; KASPAR, T. C. Identifying potential soybean management zones from multi-year yield data. **Computer and electronics in agriculture**, online, v. 46, n. 3, p. 309-327, 2005.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining Geostatistics**. New York, NY: The Blackburn Press, 1978. 600 p.

KHOSLA, R.; FLEMING, K.; DELGADO, J. A.; SHAVER, T. M.; WESTFALL, D. G. Use of site-specific management zones to improve nitrogen management for precision agriculture. **Journal of Soil and Water Conservation**, online, v. 57, n. 6, p. 513-518, 2002.

KITCHEN, N. R.; SUDDUTH, K. A.; MYERS, D. B.; DRUMMOND, S. T.; HONG, S. Y. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. **Computers and Electronics in Agriculture**, online, v. 46, n. 3, p. 285-308, 2005.

LI, Y.; SHI, Z.; LI, F.; LI, H. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, online, v. 56, n. 1, p. 174-186, 2007.

MILNE, A. E.; WEBSTER, R.; GINSBURG, D.; KINDRED, D. Spatial multivariate classification of an arable Field into compact management zones based on past crop yields. **Computers and Electronics in Agriculture**, online, v. 80, n. 1, p. 17-30, 2012.

MORAL, F. J.; TERRÓN, J. M.; REBOLLO, F. J. Site-specific management zones based on the Rasch model and geostatistical techniques. **Computers and Electronics in Agriculture**, online, v. 75, n. 2, p. 223-230, 2011.

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**, online, v. 68, n. 1, p. 97-107, 2009.

NKOKA, F.; VELDWISCH, G. J.; BOLDING, A. Organizational Modalities of Farmer-led Irrigation Development in Tsanganano District, Mozambique. **Water Alternatives**, Montpellier, v. 7, n. 2, p. 414-433, 2014.

PEDROSO, M.; TAYLOR, J.; TISSEYRE, B.; CHARNOMORDIC, B.; GUILLAUME, S. A segmentation algorithm for the delineation of agricultural management zones. **Computers and Electronics in Agriculture**, online, v. 70, n. 1, p. 199-208, 2010.

PERALTA, N. R.; COSTA, J. L. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. **Computers and Electronics in Agriculture**, online, v. 99, n. 1, p. 218-226, 2013.

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

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BIER, V. A.; BETZEK, N. M.; GAVIOLI, A. Data Interpolation in the definition of management zones. **Acta Scientiarum Technology**, Maringá, v. 38, n. 1, p. 31-40, 2016.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHEPERS, J. S.; JOHNSON, S. Appropriateness of Management Zones for Characterizing Spatial Variability of Soil Properties and Irrigated Corn Yields across Years. **Agronomy Journal**, Madison, v. 96, n. 1, p. 195-203, 2004.

SUN, Y.; KANG, S.; LI, F.; ZHANG, L. Comparison of interpolation methods for depth to groundwater and its temporal and spatial variations in the Minqin oasis of northwest China. **Environmental Modelling & Software**, online, v. 24, n. 10, p. 1163-1170, 2009.

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

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

XIN-ZHONG, W.; GUO-SHUN, L.; HONG-CHAO, H.; ZHEN-HAI, W.; QING-HUA, L.; WEI-HONG, H.; YAN-TAO, L. Determination of management zones for a tobacco Field based on soil fertility. **Computers and Electronics in Agriculture**, online, v. 65, n. 2, p. 168-175, 2009.

YAO, R.; YANG, J.; ZHANG, T.; GAO, P.; WANG, X.; HONG, L.; WANG, M. Determination of site-specific management zones using soil physico-chemical properties and crop yields in coastal reclaimed farmland. **Geoderma**, online, v. 232-234, n. 1, p. 381-393, 2014.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, online, v. 8, n. 1, p. 338-353, 1965.

7 ARTIGO 3:**SOFTWARE PARA CONTROLE DE INFORMAÇÕES DE CAMPO E DEFINIÇÃO DA EXPERIÊNCIA DO PRODUTOR PARA GERAÇÃO DE ZONAS DE MANEJO**

RESUMO: O setor agrícola se direciona cada vez mais para uma gestão inteligente de todas as etapas do sistema de produção, fazendo uso de softwares especialistas de apoio à decisão e tecnologia embarcada em máquinas. Alinhado a isso está a substituição crescente do uso de computadores desktop por dispositivos móveis, que oferecem maior mobilidade e facilidade de acesso. No contexto da agricultura de precisão o delineamento de zonas de manejo (ZMs) tem sido uma alternativa para proporcionar uma solução econômica, assim como utilizar o conhecimento das lavouras pelo produtor, apesar de subjetivo, é uma alternativa para determinar seus limitantes. O objetivo desse trabalho foi apresentar um software para dispositivos móveis aplicado no registro e gerenciamento das informações de operações de campo e definição da variável experiência do produtor para geração de ZMs. O AgData-Mobile foi desenvolvido para rodar em dispositivos com sistema operacional Android e, para avaliar as suas funcionalidades e confirmar a metodologia a ele aplicada, utilizou-se dados de uma área experimental localizada no município de Céu Azul - PR. A metodologia de utilização da experiência do produtor para geração de ZMs se mostrou eficiente como uma variável simples e de baixo custo. O software proposto permite fazer o registro da variável experiência do produtor, além de poder também fazer o registro de dados de campo, podendo manter um histórico de todas as operações e ocorrências de uma safra, sendo estes dados armazenados localmente no dispositivo móvel e em um servidor de dados. A gratuidade do software também permitirá que os produtores tenham maior facilidade no acesso a essa ferramenta.

PALAVRAS-CHAVE: dispositivos móveis; gerenciamento agrícola; unidades de manejo.

SOFTWARE FOR CONTROL OF FIELD INFORMATION AND DEFINITION OF VARIABLE FARMER'S EXPERIENCE FOR GENERATION OF MANAGEMENT ZONES

ABSTRACT: The agricultural sector is moving increasingly towards intelligent management of all stages of the production system, making use of decision support software and machine-seized technology. Aligned to this is the increasing substitution of desktop computers for mobile devices, which offer greater mobility and easier access. In the context of precision agriculture, the delineation of management zones (MZs) has been an alternative to provide an economic solution; as well as using the farmer's knowledge of the crops, despite subjective, is an alternative to determine its limitations. The objective of this work was to present a piece of software for mobile devices applied in the registration and management of field operations information and definition of the variable farmer's experience for MZ generation. AgData-Mobile was developed to run on devices with Android operating system and, to evaluate its functionalities and confirm the methodology applied, data from an experimental area located in the municipality of Céu Azul, state of Paraná, in Brazil, was used. The methodology of using the farmer's experience to generate ZMs proved to be efficient as a simple and low cost variable. The proposed software allows the registration of the variable farmer's experience, as well as being able to record field data, and can keep a history of all the operations and occurrences of a harvest, data which is stored locally on the mobile device and on a server of data. The software being free for use will also make it easier for farmers to access this tool.

KEYWORDS: mobile devices; agricultural management; management units.

7.1 Introdução

O setor de produção agrícola se encaminha para uma gestão inteligente da produção. Segundo Sorensen et al. (2011), é preciso aumentar as margens de lucro com a mais alta qualidade dos produtos cultivados e manter as áreas produtoras em conformidade com as normas ambientais. Neste sentido, o uso de sistemas de informação e apoio à decisão na gestão agrícola tem grande potencial para atingir esses objetivos, especialmente no contexto da agricultura de precisão.

Para realizar a gestão da produção agrícola, os produtores necessitam obter e manter registros de dados de diversas variáveis, a fim de permitir que por meio da avaliação destes dados possam obter informações importantes para a tomada de decisão (SORENSEN et al., 2010), apesar de que gerenciar manualmente um número elevado de tipos de dados pode ser uma tarefa difícil, dificultando inclusive suas análises para a tomada de decisões (ATHERTON et al., 1999; PEDERSEN et al., 2006; REICHARDT; JUERGENS, 2009).

O delineamento de zonas de manejo (ZMs) tem sido uma alternativa para proporcionar uma solução econômica para a agricultura de precisão, funcionando como unidades de operação para aplicação localizada de insumos e como indicador para amostragem do solo e da cultura (SCHEPERS et al., 2004; MILANI et al., 2006; ORTEGA; SANTIBÁÑEZ, 2007). Tal metodologia permite o uso dos equipamentos da agricultura convencional, já que a aplicação é variável somente entre zonas.

Embora haja inúmeros métodos e técnicas já desenvolvidas na busca pelo conhecimento da complexa dinâmica que envolve a interação entre o solo, a água e as culturas, há de se considerar que o conhecimento das lavouras pelo produtor, apesar de subjetivo, é bastante eficiente para determinar seus limitantes. Os produtores sabem quais áreas de um talhão apresentam grandes rendimentos e quais áreas que são de baixa produtividade, tendo em vista que as necessidades nutricionais e/ou características físicas são diferentes entre essas áreas, proporcionando restrições à produtividade. Fazer uso dessa base de conhecimento pode permitir a identificação de diferentes zonas de gestão em um campo, com base no histórico de produção (FLEMING; WESTFALL, 2000; MORARI et al., 2009).

Nesse contexto Hörbe et al. (2013) delimitaram ZMs com base no conhecimento do agricultor e classificaram uma área agrícola em zonas de alta, média e baixa performance na produtividade da cultura do milho, chegando ao número ideal de três ZMs, sendo que a análise de variância indicou heterogeneidade da fertilidade do solo entre as ZMs geradas. Nkoka et al. (2014) implantou sistemas de irrigação em Moçambique que operam de acordo com o contexto específico de cada área e cada sistema exibe um padrão único de gestão, baseados no histórico que o agricultor tem da área. Fleming et al. (2004) compararam

mapas de prescrição desenvolvidos a partir da experiência do produtor com mapas de prescrição desenvolvidos a partir de análises da fertilidade do solo, em duas áreas de milho no Colorado, Estados Unidos e os resultados da análise de variância foram semelhantes ao comparar os dois métodos. Khosla et al. (2002) também gerou ZMs utilizando a cor do solo obtida por meio de imagens aéreas, topografia e a experiência dos agricultores no histórico de rendimento da área e concluiu que o tratamento baseado nas ZMs permitiu gerenciar melhor a variabilidade do campo do que tratamentos convencionais.

Apesar da importância de se considerar o conhecimento empírico do produtor para a definição das possíveis restrições à produtividade das culturas, a dificuldade no levantamento dessa variável corresponde a um dos possíveis impedimentos para sua utilização, já que o ideal é que o produtor realize a campo o registro de sua percepção.

Com a popularização da informática, em especial dos dispositivos móveis, o agricultor tem à sua disposição softwares especialistas de gerenciamento e coleta dados em campo, importantes na tomada de decisão. López-Riquelme et al. (2016) afirmaram que os pesquisadores devem investir em softwares para gerenciamento agrícola utilizando o conceito de nuvem, o que permite o gerenciamento centralizado dos dados de forma integrada com diversos dispositivos. Além disso, a disponibilização de informações importantes no contexto agrícola já são previstas em aplicativos para dispositivos móveis como o mGovernment (Ntaliani et al., 2008), que fornece informações de regulamentos agrícolas, previsões do tempo, alertas de condições climáticas extremas, surtos de doenças, preço dos produtos, oferta e procura. Há o Kilimo Salama (SYNGENTA FOUNDATION, 2010), referente a uma linha de orientação para aquisição e aplicação de insumos baseado em estações meteorológicas que fornecem dados de precipitação, temperatura, velocidade do vento, luz solar, permitindo ainda prever a incidência de doenças e outros riscos potenciais com base nesses dados climáticos. Tem-se também o software CR Campeiro, criado no Brasil e que oferece um conjunto de aplicativos voltados ao gerenciamento agrícola (UFESM, 2016).

Nesse contexto, o objetivo desse estudo foi desenvolver um software para dispositivos móveis aplicado no registro e no gerenciamento das informações de operações de campo e definição da variável experiência do produtor para a geração de ZMs, com um estudo de caso para validação da utilização dessa variável no processo de geração de ZMs.

7.2 Material e métodos

7.2.1 Tecnologias de análise e desenvolvimento do software AgData-Mobile

Na análise e no projeto do aplicativo AgData-Mobile foi empregada a linguagem de modelagem unificada (UML), a fim de especificar, construir e documentar os modelos de análise e projeto. Para produzi-los, foi utilizada a ferramenta de modelagem Astah Community 7.0. O modelo de análise foi constituído pela listagem de requisitos funcionais e não funcionais do software, pela lista de dependências entre requisitos e pelos diagramas de casos de uso. Com isso, foi obtida uma visão sobre o que o aplicativo deve realizar e sobre as restrições de execução das funcionalidades.

O AgData-Mobile foi desenvolvido para rodar em dispositivos com sistema operacional Android, sendo que tal plataforma foi escolhida por ter distribuição gratuita e abranger a maior parte do mercado de dispositivos móveis. No processo de desenvolvimento foi utilizada a IDE (Integrated Development Environment) Android Studio 2.1.1 e o aplicativo foi desenvolvido utilizando as ferramentas disponíveis no software Development Kit (SDK) da plataforma Android.

Também foram utilizadas algumas bibliotecas do Android para desenvolvimento de funcionalidades específicas (Tabela 1). A persistência dos dados é realizada localmente no banco de dados SQLite, que é um banco de dados Open Source, incorporado no Android. O armazenamento dos dados localmente permite que o aplicativo funcione em locais sem conexão com a internet, sendo que posteriormente ao se conectar em uma rede internet os dados são enviados para o servidor do AgDataField e armazenados no banco de dados PostgreSQL.

Tabela 1 Bibliotecas Android utilizadas para o desenvolvimento do aplicativo AgData-Mobile

Nome	Versão	Função
Android Aquery	0.26.7	Comunicação AJAX
Google play services	8.4.0	Mapas e localização
Sugar ORM	1.3.1	Persistência
SQLite	3.8	Persistência
Gson	2.4	Serialização
Android Support	23.4.0	Design
Android maps Utils	0.4	Cálculos com áreas

Para o funcionamento do aplicativo é necessário que o dispositivo móvel possua no mínimo a versão 4.1 (Jelly Bean) do Android e a plataforma Android 6.0 (Marshmallow), que corresponde à última versão disponível no início do processo de desenvolvimento (fevereiro de 2016).

O funcionamento do aplicativo AgData-Mobile ocorre conforme o fluxograma apresentado na Figura 1. Ao acessar o menu inicial, o usuário deve primeiro cadastrar a área com a qual deseja trabalhar e depois inserir os dados da safra agrícola corrente

(histórico da produção) e realizar o registro da variável experiência do produtor, a qual será utilizada para a geração das ZMs no software AgDataFieldMap.

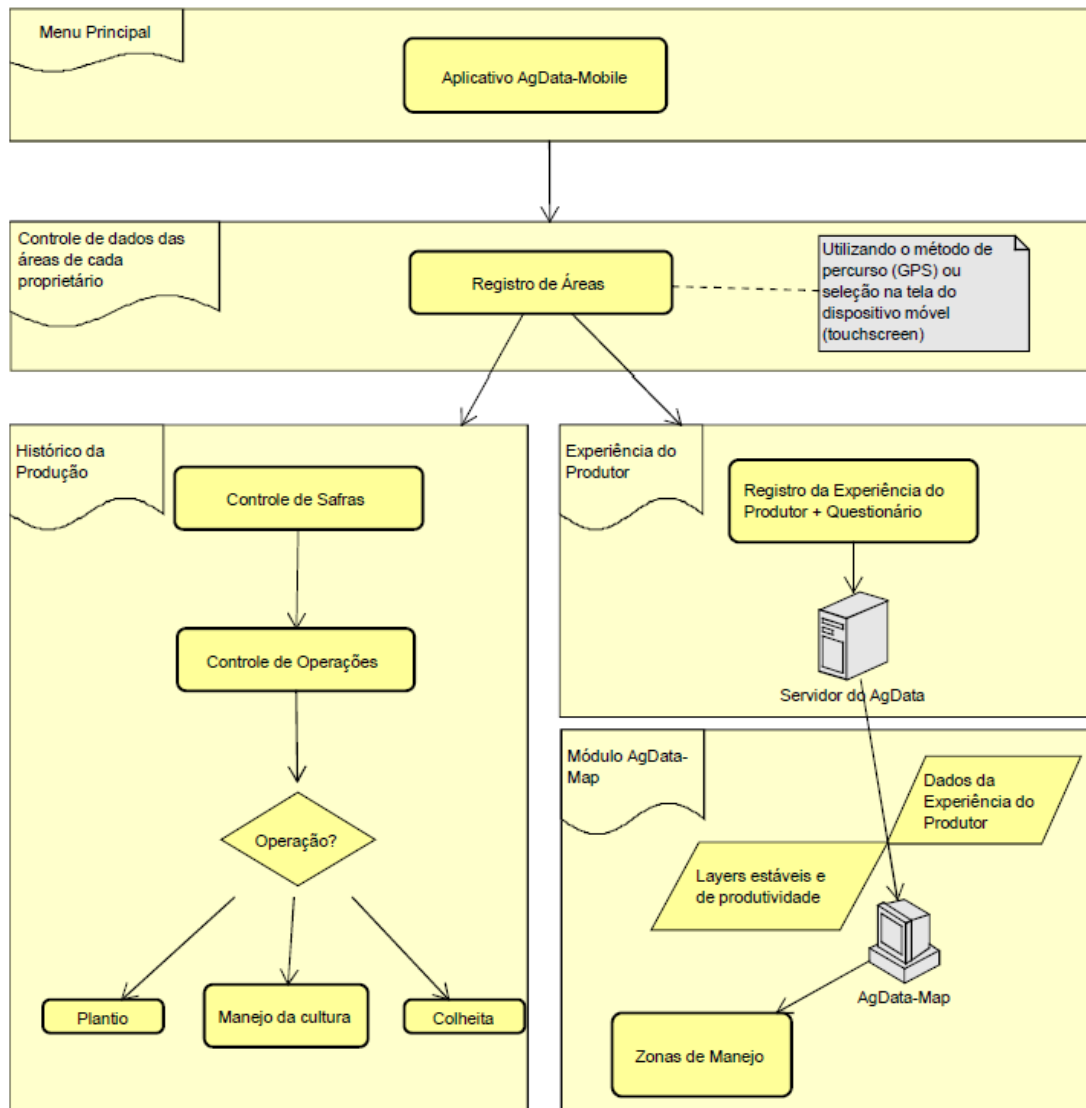


Figura 1 Fluxograma de funcionamento do aplicativo AgData-Mobile.

7.2.2 Estudo de caso

Para avaliar as funcionalidades do software AgData-Mobile e confirmar a metodologia a ele aplicada, utilizou-se dados de uma área experimental (Figura 2) de aproximadamente 15,5 ha, localizada no município de Céu Azul - PR, com localização geográfica central de 25°06'32" S e 53°49'55" O e elevação média de 620 m.

O solo da área em estudo foi classificado como LATOSSOLO VERMELHO Distroférico (EMBRAPA, 2006) e vem sendo cultivado há mais de dez anos sob sistema de plantio direto com sequência de culturas soja, trigo, milho e aveia. Foi definida nessa área uma grade amostral irregular, levando em conta uma linha central imaginária entre as curvas de nível, e foi utilizada uma malha de amostragem densa com 2,58 pontos ha⁻¹, a fim de

satisfazer as restrições da análise geoestatística (JOURNEL; HUIJBREGTS, 1978) quanto ao número mínimo de 30 pares para cálculo das semivariâncias do semivariograma.




Figura 2 Delimitação da área amostral.

Seguindo recomendações de Doerge (2000) e Fridgen et al. (2004), no processo de definição das ZMs, além da variável experiência do produtor, foram utilizadas variáveis do solo consideradas temporalmente estáveis (Tabela 2). Isto porque a intenção é de que as variáveis consideradas nesse processo conduzam à definição de ZMs válidas por vários anos. Assim, atributos químicos não foram considerados.

Tabela 2 Variáveis coletadas na área experimental em cada ano de estudo

Variáveis (atributos)	2012	2013	2014	2015
Densidade (g cm^{-3})	X	X	X	X
Elevação (m)	X			
MO (%)	X	X	X	X
Areia (%)	X			
Silte (%)	X			
Argila (%)	X			
Declividade ($^{\circ}$)	X			
RSP 0-0,1 m (MPa)	X	X	X	X
RSP 0,1-0,2 m (MPa)	X	X	X	X
RSP 0,2-0,3 m (MPa)	X	X	X	X
Produtividade da soja (t ha^{-1})	X	X	X	X
Experiência do Produtor				X

RSP – Resistência do Solo a Penetração; MO – Matéria Orgânica.

A elevação foi determinada utilizando uma estação eletrônica Topcon GPT-7505. Na medição da resistência do solo a penetração (RSP) foi empregado um penetrógrafo Falker PGL 1020 e posteriormente calculada a média para cada profundidade 0-0,1 m, 0,1-0,2 m, 0,2-0,3 m. As amostras de solo foram coletadas na profundidade de 0-0,2 m e enviadas ao laboratório para análise dos atributos texturais do solo.

A produtividade da soja foi determinada com um monitor de colheita CASE AFS PRO 600 acoplado a uma colhedora Case 2388. Os dados de produtividade dos quatro anos

agrícolas (2012 à 2015) (Figuras 3a – 3d) foram normalizados por meio do método da média (Equação 1) (SWINDEL, 1997), com o objetivo de atender ao requisito de estabilidade desses dados, que geralmente são bastante influenciados pelas variações do clima e da precipitação. Em seguida, calculou-se a média aritmética dos valores normalizados dos anos disponíveis, gerando-se uma única variável, correspondente à média das produtividades normalizadas (Figura 3e).

$$P_{iN} = \frac{P_i}{\bar{P}} \quad \text{Eq. (1)}$$

em que, P_{iN} - pixel i normalizado; P_i - pixel i a ser normalizado; \bar{P} - média aritmética de todos os pixels do mapa a ser normalizado.

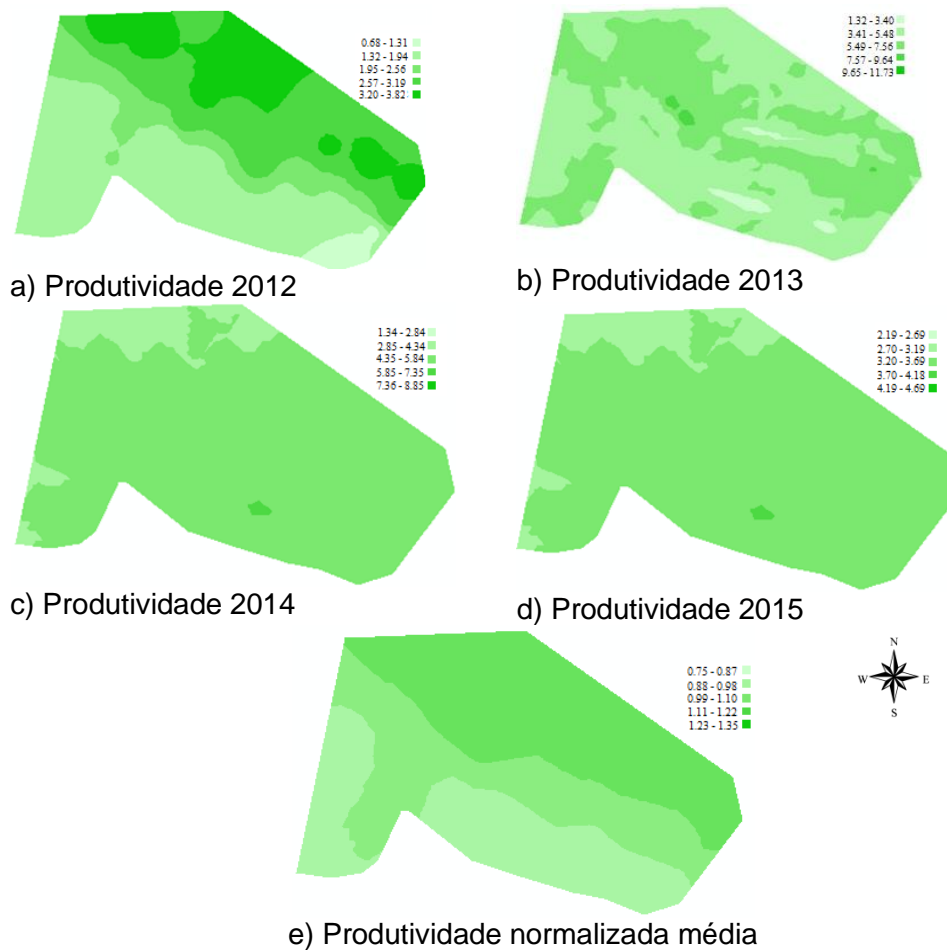


Figura 3 Mapas de produtividade dos quatro anos agrícolas (2012, 2013, 2014 e 2015) e produtividade média normalizada interpolados por krigagem ordinária.

A variável experiência do produtor foi determinada pelo produtor por meio do aplicativo AgData-Mobile, instalado em um smartphone, dividindo-se o talhão em três classes (alta, média e baixa) de produtividade baseado na experiência de anos anteriores de cultivo da área, inserindo a produtividade média para cada uma das classes, criando-se, assim, a variável numérica experiência do produtor.

Para selecionar as variáveis necessárias para a definição das ZMs utilizando métodos de agrupamento, Córdoba et al. (2013) e Gavioli et al. (2016) compararam algumas

técnicas considerando conjuntos de dados multivariados correspondentes a áreas com existência de dependência espacial. Eles mostraram que a técnica análise multivariada espacial com base no índice de Moran PCA (MULTISPATI-PCA) (DRAY et al., 2008) proporcionou os melhores resultados na maioria dos casos. Dessa forma, foi utilizada a abordagem proposta por Gavioli et al. (2016), chamada de MPCA-SC e que se baseia na utilização da estatística de autocorrelação espacial bivariada de Moran (ORD, 1975) em conjunto com MULTISPATI-PCA.

MPCA-SC adiciona uma restrição espacial à PCA tradicional, possibilitando que esta seja executada considerando a existência de dependência espacial em conjuntos de dados georreferenciados. Na definição dessa abordagem, foi introduzida uma matriz de ponderação espacial à PCA, construída utilizando-se a estatística de autocorrelação espacial bivariada de Moran. MPCA-SC tem como vantagem em relação à PCA o fato de maximizar a autocorrelação espacial entre pontos, enquanto PCA maximiza a variância total (CÓRDOBA et al., 2013; GAVIOLI et al., 2016).

Aplicando-se MPCA-SC foram geradas no software R novas variáveis sintéticas adequadas para serem utilizadas como entradas no método de agrupamento para a geração das ZMs. Cada variável sintética, chamada de componente principal espacial (PCS), foi definida como uma combinação linear das variáveis originais que apresentaram correlação espacial significativa com a produtividade média normalizada da área considerada. Assim, na formação das componentes principais espaciais (SPCs) foram utilizadas as seguintes variáveis originais: experiência do produtor, elevação, argila, areia e RSP 0,0-0,1 m.

O conjunto de dados de entrada do método de agrupamento foi formado pelas coordenadas e pelos valores obtidos para as duas primeiras SPCs (SPC1 e SPC2). A decisão de utilizar apenas as duas primeiras SPCs foi tomada com base no critério sugerido por Johnson e Wichern (2007), que recomendam utilizar a quantidade de componentes principais suficiente para representar ao menos 70% da variância total dos dados originais (Tabela 3).

Tabela 3 Porcentagem da variância total dos dados representada pela SPC e somatório das porcentagens correspondentes às SPCs

Variável	% da variância total	% Acumulada da variância total
SPC1	62,0%	62,0%
SPC2	19,0%	81,0%

Várias técnicas de interpolação dados podem ser utilizadas para gerar ZMs com contornos mais suaves e para reduzir a variância dos dados. Em uma análise comparativa de técnicas de interpolação utilizadas antes do processo de agrupamento, Schenatto et al.

(2016) constatou-se que a krigagem ordinária obteve o melhor desempenho; assim, optou-se por este interpolador neste trabalho.

Para aplicação da krigagem ordinária, foi realizada a análise geoestatística das SPCs (SPC1 e SPC2) ajustando-se ao semivariograma experimental os modelos esférico, exponencial e gaussiano, sendo que o melhor modelo foi determinado por meio da estatística de validação cruzada (SUN et al., 2009; ARSLAN, 2012). Os dados foram então interpolados por krigagem ordinária, a fim de criar uma grade de 5 x 5 m, com maior detalhamento dos atributos.

Depois de interpolados no software ArcMap 9.3, os dados resultantes das variáveis SPC1 e SPC2 foram utilizados como entrada do algoritmo de agrupamento Fuzzy C-means no software SDUM (BAZZI et al., 2013), considerando os parâmetros de erro = 0.0001 e índice de ponderação 1.3, gerando-se duas, três e quatro ZMs.

As ZMs geradas foram avaliadas quantitativamente pelos seguintes índices:

1) Redução da Variância (VR) (DOBERMANN et al., 2003; XIANG et al., 2007), Equação 2: Este índice foi calculado utilizando-se a variável produtividade média normalizada, com a expectativa que a soma das variâncias dos dados de cada zona de manejo seja menor que a variância total.

$$RV = 1 - \frac{\sum_{i=1}^c (W_i * V_{um_i})}{V_{\acute{a}rea}} * 100 \quad \text{Eq. (2)}$$

em que, c - número de ZMs; W_i - proporção da área em cada zona de manejo; V_{um_i} - variância dos dados de cada zona de manejo; $V_{\acute{a}rea}$ - variância da amostra dos dados para toda a área.

2) Índice de Desempenho Fuzzy (Fuzziness Performance Index (FPI)), Equação 3: Permite determinar o grau de separação (isto é, confusão) entre os c -clusters fuzzy de um conjunto de dados. Quando os valores de FPI se aproximam de 0 indicam classes distintas, apresentando pequeno grau de compartilhamento dos membros (dados) entre elas, enquanto que valores próximos a 1 indicam não haver classes distintas, apresentando elevado grau de compartilhamento dos membros entre as classes (FRIDGEN et al., 2004).

$$FPI = 1 - \frac{c}{(c-1)} \left[1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad \text{Eq. (3)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elemento ij da matriz de pertinência fuzzy.

3) Índice da Partição da Entropia Modificada (Modified Partition Entropy (MPE)), Equação 4: Esse índice estima a quantidade de desorganização criada por um número específico de clusters. Valores de MPE próximos de 1 indicam que predomina a

desorganização, enquanto que valores se aproximando de 0 indicam melhor organização (BOYDELL; MCBRATNEY, 2002).

$$MPE = \frac{-\sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) / n}{\log c} \quad \text{Eq. (4)}$$

em que, c - número de clusters; n - número de observações; u_{ij} - elementos ij da matriz de pertinência fuzzy.

4) Índice de Suavidade (Smooth Index (IS)), Equação 5: calcula a frequência de mudança das classes do mapa temático nas direções horizontal, vertical e das diagonais, pixel a pixel. Na hipótese de que o mapa possuísse uma área totalmente homogênea, resultaria um índice de suavidade igual a 100%, devido à ausência de mudanças de classe. Da mesma forma, se o mapa fosse completamente gerado com valores aleatórios, o índice de suavidade apresentaria um valor próximo a zero (referência).

$$SI = 100 - \left(\left(\frac{\sum_{i=1}^k NM_{Hi}}{4P_H} + \frac{\sum_{j=1}^k NM_{Vj}}{4P_V} + \frac{\sum_{l=1}^k NM_{Ddl}}{4P_{Dd}} + \frac{\sum_{m=1}^k NM_{Dem}}{4P_{De}} \right) * 100 \right) \quad \text{Eq. (5)}$$

em que, NM_{Hi} - número de mudanças na linha i (horizontal); NM_{Vj} - número de mudanças na coluna j (vertical); NM_{Ddl} - número de mudanças na diagonal l (diagonal direita - Dd); NM_{Dem} - número de mudanças na diagonal m (diagonal esquerda - De); k - número máximo de pixels na linha, coluna ou diagonais; P_H - possibilidade de mudanças de pixels na horizontal; P_V - possibilidade de mudanças de pixels na vertical; P_{Dd} - possibilidade de mudanças na diagonal direita - Dd ; P_{De} - possibilidade de mudanças na diagonal esquerda - De .

5) Análise de Variância (ANOVA): os valores de produtividade foram comparados entre as ZMs usando a produtividade média normalizada, e o teste de comparação de média de Tukey foi realizado para identificar se as sub-regiões geradas apresentaram diferenças significativas na produtividade média normalizada (após teste comprovando a inexistência de dependência espacial dentro de cada ZM).

O fluxograma da Figura 4 representa de forma resumida os passos para a geração das ZMs nesse estudo de caso, bem como os softwares utilizados nesse processo.

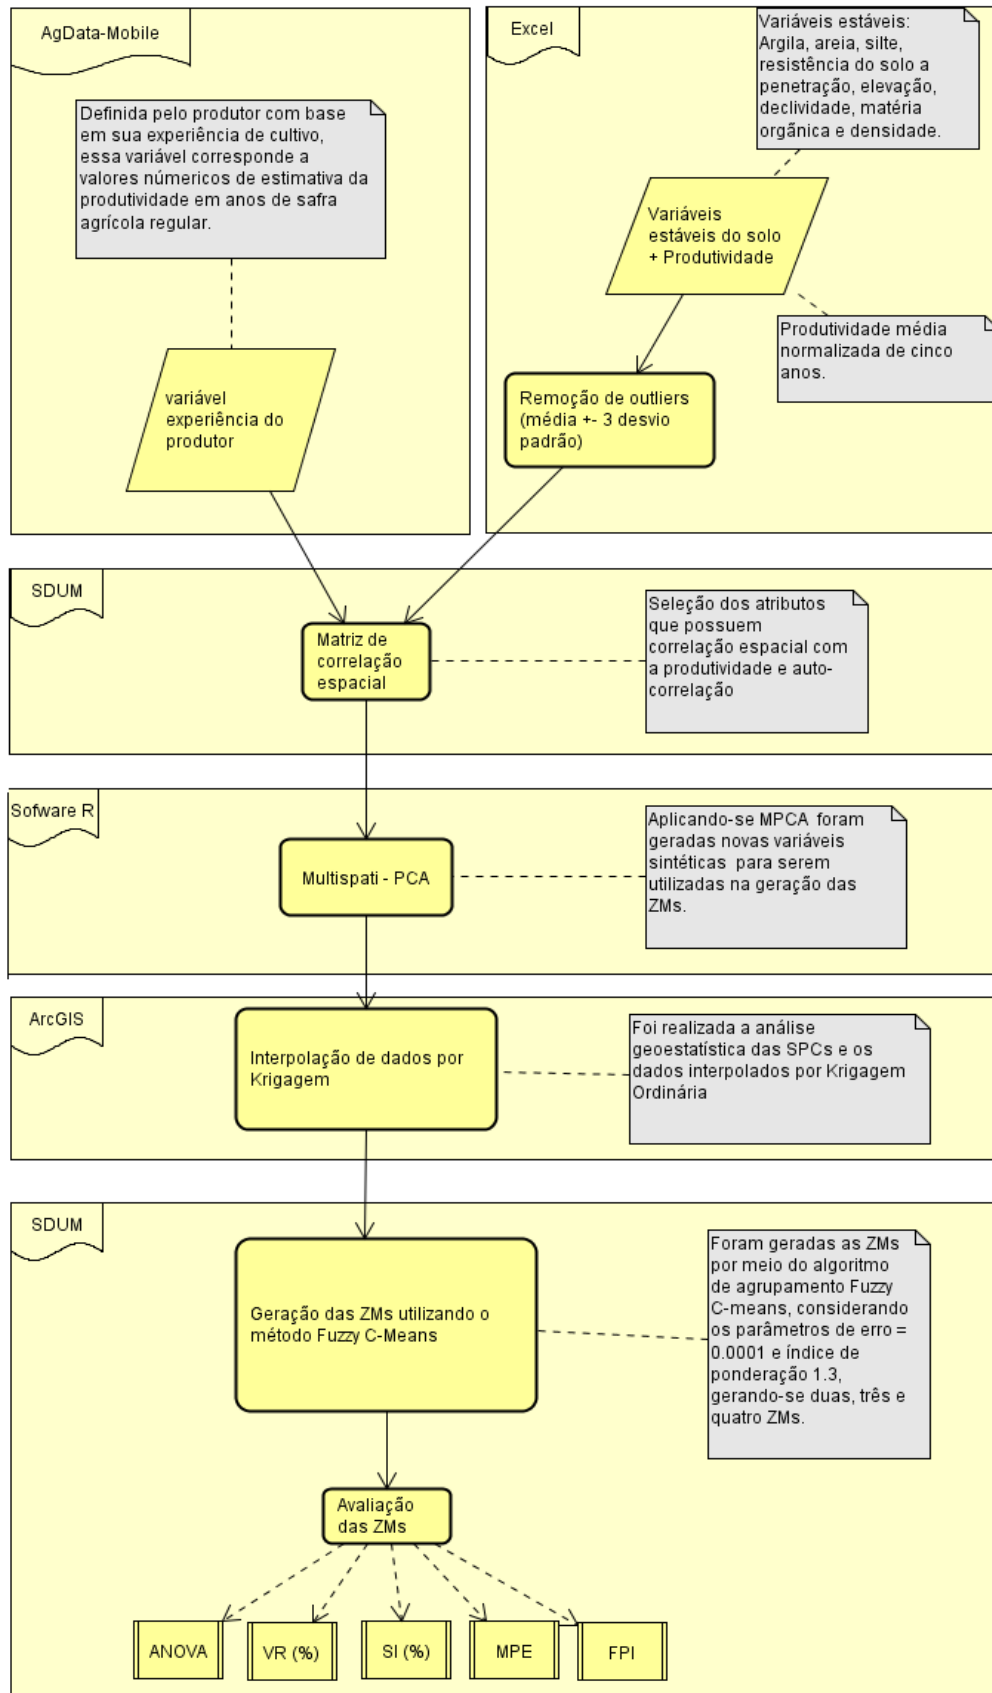


Figura 4 Fluxograma de representação do processo de geração das ZMs.

7.3 Resultados e discussão

7.3.1 Aplicativo AgData-Mobile

Para ter acesso ao AgData-Mobile é preciso baixar o aplicativo na AppStore e instalá-lo em um dispositivo que possua suporte à plataforma Android. O aplicativo instala conforme a linguagem do sistema operacional do celular, estando disponível nas versões inglês e português. Após a instalação é necessário que o usuário realize um cadastro no seu primeiro acesso (Figura 5a) ou, caso já tenha um login e senha, deve digitá-los para ter acesso à aplicação (Figura 5b). Depois de realizado o cadastro é apresentado ao usuário um menu inicial com as funções oferecidas pelo aplicativo (Figura 5b).

O aplicativo permite que o usuário realize o cadastro de áreas, dados de safra, das operações de campo (plantio, colheita e outras aplicações realizadas em cada cultura), de maquinários utilizados em tais operações e da variável experiência do produtor.

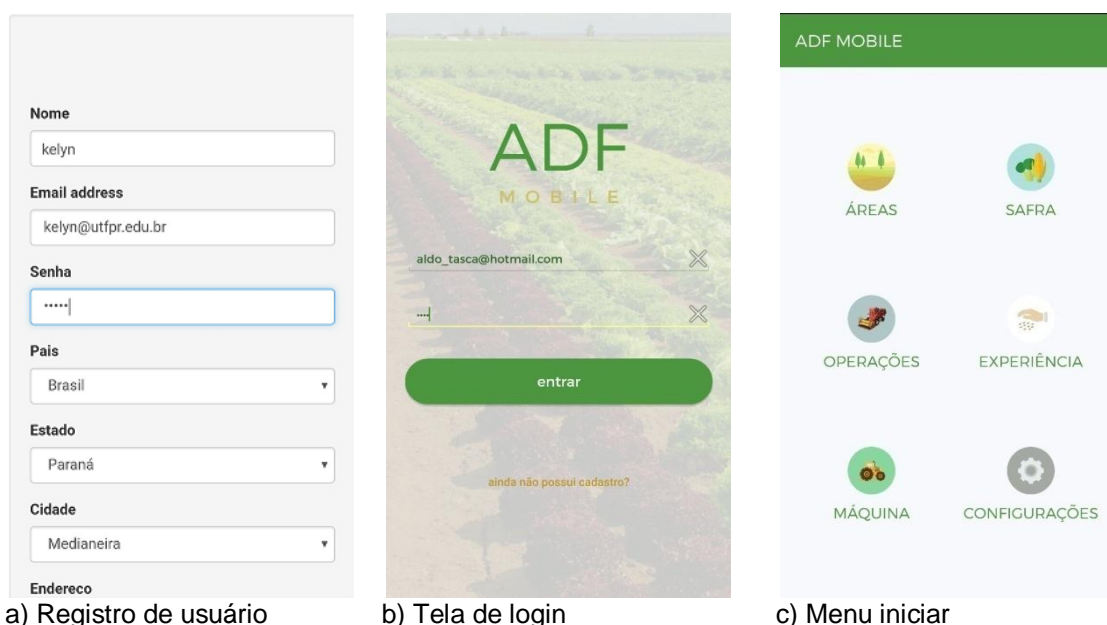


Figura 5 Telas de cadastro, login e menu inicial do software ADF Mobile (AgData-Mobile)

O produtor pode realizar o cadastro de todos os talhões de sua propriedade, ficando estes dados armazenados no banco de dados do sistema para futuras consultas. O cadastro dos talhões (Figura 6a) pode ser realizado utilizando o método de realização do percurso, onde o produtor percorre toda a borda do talhão ou por meio do método de toque na tela, em que o produtor utiliza a função touchscreen do dispositivo móvel para definir o polígono da área a ser cadastrada (Figura 6b). Ao finalizar o cadastro (Figura 6c) pode ser visualizada a área total do talhão (ha), podendo-se indicar tipo de solo do talhão e o proprietário da referida área (Figura 6d) (o registro do proprietário é importante para o caso de o usuário ser um agrônomo que administra várias propriedades).




a) Acesso a opção de cadastro de área de área b) Definição do polígono de área c) Fechamento do polígono da área d) Finalização do cadastro de área

Figura 6 Representação do processo de cadastro de área no aplicativo AgData-Mobile

A cada safra o usuário pode fazer um registro da data de início da safra e indicar qual a cultura cultivada e no término dela registrar a data de finalização da safra (Figuras 7a e 7b). Além disso, o produtor pode realizar o cadastramento de todas as operações de campo realizadas em uma determinada safra.

No exemplo (Figura 7) é realizado o registro da operação de plantio da soja, podendo o usuário inserir dados referentes à data da operação de plantio, espaçamento utilizado (Figura 7c), insumos e quantidades utilizadas (Figura 7d), quais foram os maquinários que realizaram essa operação (Figura 7e), variedade, espaçamento e quantidade de sementes (Figura 7f). Após o registro de todas as informações referentes à operação, estas ficam registradas no banco de dados do aplicativo, caso não haja conexão com internet. Ao conectar o dispositivo à internet e acessar o aplicativo, os dados cadastrados são automaticamente cadastrados no sistema AgDataField (servidor de dados).



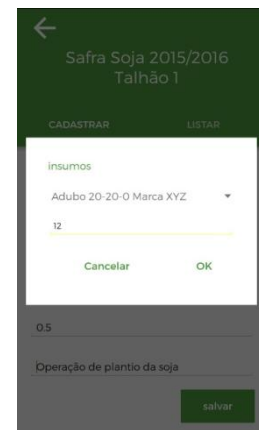
a) Registro de safra




b) Visualização de dados da safra



c) Cadastro da operação de plantio




d) Cadastro de insumos utilizados no plantio



e) Cadastro de maquinários utilizados no plantio



f) Variedade e quantidades utilizadas



g) Operação gravada no banco de dados



h) Visualização dos dados dessa operação

Figura 7 Registro de safra e da operação de plantio.

Na Figura 8 pode ser visualizado outro exemplo, referente a uma operação de pulverização realizada no Talhão 1 na safra da soja 2015/2016. Ao selecionar operação de pulverização (Figura 8a) são disponibilizados ao usuário o preenchimento de dados de quais insumos foram aplicados (Figura 8b) e maquinários utilizados (Figura 8c). Após o registro os dados devem ser gravados (fazendo uso do botão Salvar) no banco de dados do dispositivo (no caso deste encontrar-se off-line) ou no servidor do AgDataField (Figura 8d), caso haja conexão com a internet.

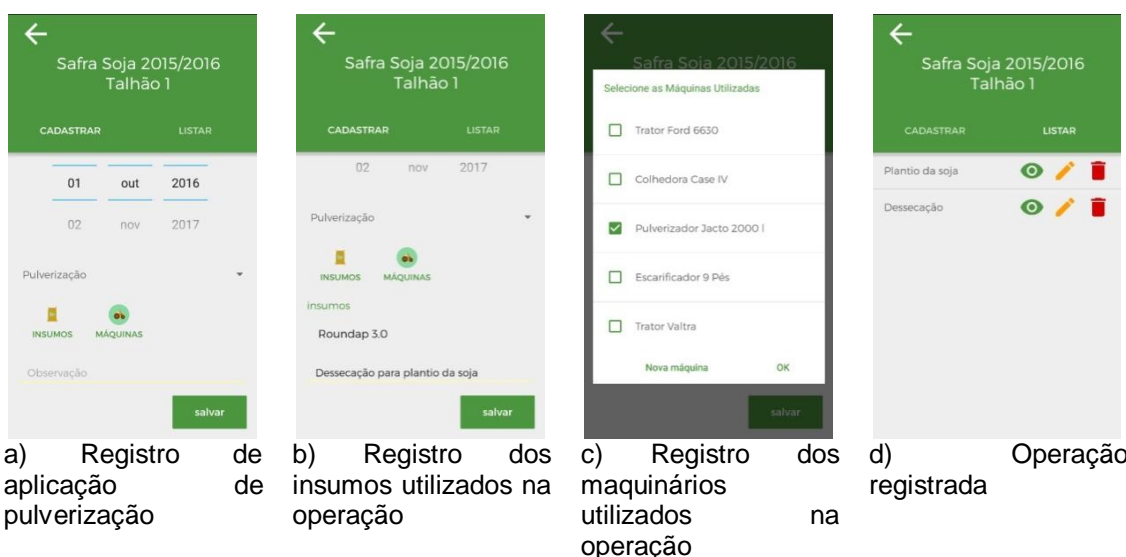
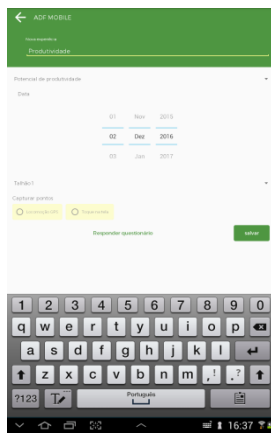


Figura 8 Registro de operação de pulverização.

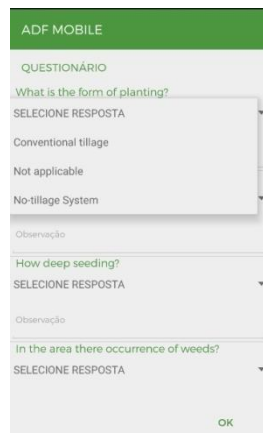
O registro da variável experiência do produtor pode indicar diferentes características de experiência, como, por exemplo, a produtividade estimada da área agrícola, que é a variável utilizada no estudo de caso deste trabalho. Além disso, o produtor pode realizar registro de reboleiras de planta daninha, locais com infestação de pragas, regiões onde ocorreram falhas de plantio ou que ocorreram problemas climáticos que interferiram em operações de campo, para que possa, assim, manter um histórico dos fatores que aconteceram na propriedade para consultas futuras.

Por meio do método de percurso ou seleção na tela, o usuário pode realizar o registro da variável experiência do produtor (Figura 9), definindo locais em que ocorreram problemas ou onde se tem a perspectiva, por exemplo, de baixa, média ou alta produtividade. É disponibilizado ao agricultor também a possibilidade de responder a um questionário de histórico da área (Figura 9b), que pode ser utilizado por um novo agrônomo que passa a administrar a propriedade.

No exemplo (Figura 9), primeiro é registrada a descrição da experiência, selecionado o tipo da experiência, data que foi gerado este dado e qual o talhão em que se deseja realizar o registro (Figura 9a). Após esta etapa, o usuário pode optar por responder a um questionário de histórico da área (Figura 9b), que pode auxiliar em decisões referentes aos fatores que podem estar influenciando a produtividade em determinados locais do talhão. Ao salvar a experiência é apresentada a área para início da divisão do talhão em classes de produtividade (Figura 9c). Após a seleção de uma sub-área do talhão (Figura 9d) o usuário deve inserir a informação do valor de produtividade e um campo de observação (Figura 9e). Assim, o usuário deve definir todas as classes de produtividade que considere dividir o talhão. Neste caso foram realizadas divisões de perspectiva de produtividade como alta (5000 kg ha^{-1}), média (4500 kg ha^{-1}) e baixa (4000 kg ha^{-1}).



a) Cadastro da experiência do produtor



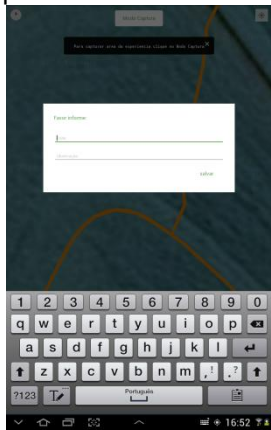
b) Questionário



c) Visualização da área escolhida



d) Definição da primeira faixa de produtividade



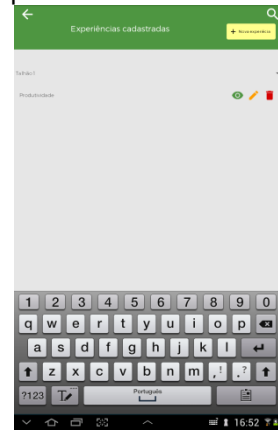
e) Definição dos valores de produtividade



f) Visualização da classe de produtividade



g) Definição da terceira classe de produtividade



h) Experiência registrada

Figura 9 Processo de definição da experiência do produtor.

Assim como foi realizado o procedimento de registro da variável experiência do produtor utilizando a produtividade, o produtor pode ainda registrar outras informações que aconteceram em algumas sub-regiões do talhão, mantendo um histórico do local exato em que aconteceu cada fator, como, por exemplo, plantas daninhas, falha no plantio, ventos, queimadas, etc.

Dessa forma, o AgData-Mobile poderá ser utilizado para o produtor manter um registro da sua área e, além disso, fornecer dados para um projeto maior chamado AgDataField, que compreende todo um sistema para gerenciamento agrícola e processo de geração de ZMs. Nesse sistema, a variável experiência do produtor é utilizada na geração de ZMs e todas as informações referentes às safras agrícolas serão utilizadas em um módulo computacional que permitirá aplicar técnicas de mineração de dados nos dados do AgDataField.

3.2 Experiência do produtor na geração de ZMs

A metodologia de geração de ZMs utilizando a variável experiência do produtor foi testada em um estudo de caso em uma área agrícola comercial. A variável experiência do produtor, que corresponde a uma estimativa de classes de produtividade alta, média e baixa definidas pelo produtor, foi demarcada utilizando o aplicativo AgData-Mobile e é apresentada na Figura 10.




Figura 10 Variável experiência do produtor obtida por meio do AgData-Mobile.

Além da variável experiência do produtor foram utilizadas para geração das SPCs as variáveis do solo altitude, argila, areia e RSP 0,0-0,1 m (Figura 11), que foram as variáveis que correlacionaram com a produtividade e apresentaram autocorrelação.

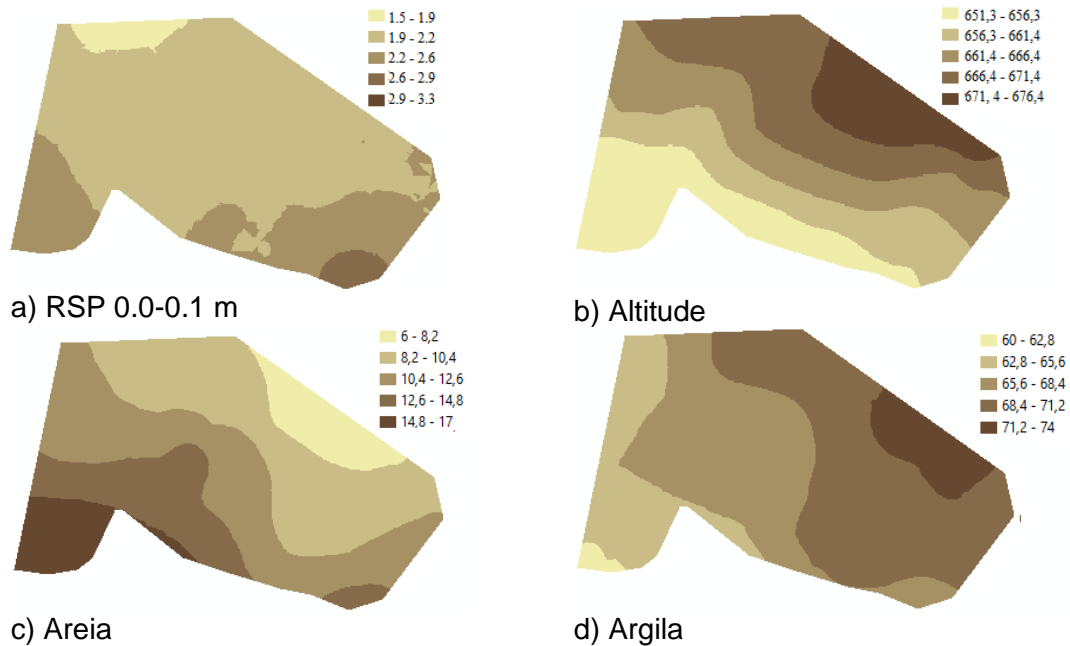


Figura 11 Mapas temáticos das variáveis do solo RSP 0,0-0,1 m, altitude, areia e argila.

A partir das variáveis RSP 0,0-0,1 m, altitude, areia, argila e experiência do produtor foram geradas as variáveis SPC 1 e SPC 2, obtidas por meio da técnica MPCA, e então definidas as ZMs, com duas, três e quatro classes (Figura 12).




Figura 12 Zonas de manejo geradas utilizando as variáveis SPC1 e SPC2.

Os melhores resultados estatísticos para as ZMs avaliados pelo FPI, MPE e IS (Tabela 4) correspondem à divisão em duas ZMs, uma vez que foi obtido o maior IS (98,45) e os menores FPI (0,03) e MPE (0,14). Os resultados do VR indicam que a melhor divisão foi em quatro classes, pois conseguiu-se reduzir uma porcentagem maior da variância dos dados, o que é esperado quando divide-se as áreas em mais classes de manejo. Porém, quando a divisão foi em duas classes, conseguiu-se reduzir 55% da variância dos dados dentro de cada agrupamento em relação à variância total. Além disso, é possível verificar que quando geradas duas e três ZMs, a ANOVA indicou potencial produtivo distinto para cada zona.

Tabela 4 Estatísticas de avaliação das zonas de manejo geradas (ZMs)

Nº ZMs	ZM1	ZM 2	ZM 3	ZM 4	VR(%)	FPI	MPE	IS
2	A	b			55,16	0,14	0,03	98,4
3	A	b	c		23,66	0,25	0,05	96,8
4	A	a	b	b	57,98	0,24	0,05	95,9

7.4 Conclusões

O software desenvolvido AgData-Mobile possibilita uma fácil e amigável ferramenta mobile de registro e gerenciamento das informações de operações de campo e definição da variável experiência do produtor para a geração de ZMs.

A gratuidade do software permite que os produtores tenham acesso fácil a essa ferramenta e possam utilizá-la.

7.5 Referências

ARSLAN, H. Spatial and temporal mapping of groundwater salinity using ordinary kriging and indicator kriging: The case of Bafra Plain, Turkey. **Agriculture Water Management**, online, v. 113, n. 1, p. 57-63, 2012.

ATHERTON, B. C.; MORGAN, M. T.; SHEARER, S. A.; STOMBAUGH, T. S.; WARD, A. D. Site specific farming: a perspective on information needs, benefits and limitations. **Journal of Soil and Water Conservation**, online, v. 54, n. 2, p. 455–461, 1999.

BAZZI, C. L.; SOUZA, E. G.; OPAZZO, M. U.; NOBREGA, L. H.; ROCHA, D. M. Management Zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, online, v. 33, n. 5, p. 952-964, 2013.

BOYDELL, B.; MCBRATNEY, A. B. Identifying potential within-field management zones from cotton yield estimates. **Precision Agriculture**, online, v. 3, n. 1, p. 9-23, 2002.

CORDOBA, M.; BRUNO, C.; COSTA, J. L.; BALZARINI, M. Subfield management class delineation using cluster analysis from spatial principal components of soil variables. **Computers and Electronics in Agriculture**, online, v. 97, n. 1, p. 6-14, 2013.

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

DOERGE, T. A. **Management zones concepts**. Norcross: Potash & Phosphate Institute, 2000, 135 p.

DRAY, S.; SAÏD, S.; DÉBIAS, F. Spatial ordination of vegetation data using a generalization of Wartenberg's multivariate spatial correlation. **Journal of Vegetation Science**, online, v. 19, n. 1, p. 45-56, 2008.

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

FLEMING, K. L.; HEERMANN, D. F.; WESTFALL, D. G. Evaluating Soil Color with Farmer Input and Apparent Soil Electrical Conductivity for Management Zone Delineation. **Agronomy Journal**, Madison, v. 96, n. 1, p. 1581-1587, 2004.

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

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.

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, online, v. 127, n. 1, p. 302-310, 2016.

HÖRBE, T. A. N.; AMADO, T. J. C.; FERREIRA, A. O.; ALBA, P. J. Optimization of corn plant population according to management zones in Southern Brazil. **Precision Agriculture**, online, v. 14, n. 4, p. 450-465, 2013.

JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**. 6.ed. New Jersey: Pearson, 2007. 800 p.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining Geostatistics**. New York, NY: The Blackburn Press, 1978. 600 p.

KHOSLA, R.; FLEMING, K.; DELGADO, J. A.; SHAVER, T. M.; WESTFALL, D. G. Use of site-specific management zones to improve nitrogen management for precision agriculture. **Journal of Soil and Water Conservation**, Ankeny, v. 57, n. 6, p. 513-518, 2002.

LÓPEZ-RIQUELME, J. A.; PAVÓN-PULIDO, N.; NAVARRO-HELLÍN, H.; SOTO-VALLES, F.; TORRES-SÁNCHEZ, R. A software architecture based on firmware cloud for precision agriculture. **Agricultural Water Management**, online, v.12, n.1, p. 1-13, 2016.

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

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**, online, v. 68, n. 1, p. 97-107, 2009.

NKOKA, F.; VELDWISCH, G. J.; BOLDING, A. Organisational Modalities of Farmer-led Irrigation Development in Tsangano District, Mozambique. **Water Alternatives**, Montpellier, v. 7, n. 2, p. 414-433, 2014.

NTALIANI, M.; COSTOPOULOU, C.; KARETSOS, S. Mobile government: a challenge for agriculture. **Government Information Quarterly**, online, v. 25, n. 1, p. 699-716, 2008.

ORD, J. K. Estimation methods for models of spatial interaction. **Journal of the American Statistical Association**, online, v. 70, n. 349, p. 120-126, 1975.

ORTEGA, R. A.; SANTIBÁÑEZ, O. A. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. **Computers and Electronics in Agriculture**, online, v. 58, n. 1, p. 49-59, 2007.

PEDERSEN, S. M.; FOUNTAS, S.; BLACKMORE, B. S.; GYLLING, M.; PEDERSEN, J. L. Adoption and perspective of precision farming in Denmark. **Acta Agriculturae Scandinavica**, online, v. 54, n. 1, p. 2-8, 2006.

REICHARDT, M.; JUERGENS, C. Adoption and future perspective of precision farming in Germany: results of several surveys among different agricultural target groups. **Precision Agriculture**, online, v. 10, n. 1, p. 73-94, 2009.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BIER, V. A.; BETZEK, N. M.; GAVIOLI, A. Data Interpolation in the definition of management zones. **Acta Scientiarum Technology**, Maringá, v. 38, n. 1, p. 31-40, 2016.

SCHEPERS, A. R.; SHANAHAN, J. F.; LIEBIG, M. A.; SCHEPERS, J. S.; JOHSON, S. H.; LUCHIARI, A. Appropriateness of Management Zones for Characterizing Spatial Variability of Soil Properties and Irrigated Corn Yields across Years. **Agronomy Journal**, Madison, v. 96, n. 1, p. 195-203, 2004.

SORENSEN, C. G.; FOUNTAS, S.; NASH, E.; PESONEN, L.; BOCHTIS, D.; PEDERSEN, S. M.; BASSO, B.; BLACKMORE, S. B. Conceptual model of a future farm management information system. **Computers and Electronics in Agriculture**, online, v. 72, n. 2, p. 37-47, 2010.

SORENSEN, C. G.; PESONEN, L.; BOCHTIS, D. D.;VOUGIOUKAS, S. G.; SUOMI, P. Functional requirements for a future farm management information system. **Computers and Electronics in Agriculture**, online, v. 76, n. 2, p. 266-276, 2011.

SUN, Y.; KANG, S.; LI, F.; ZHANG, L. Comparison of interpolation methods for depth to groundwater and its temporal and spatial variations in the Minqin oasis of northwest China. **Environmental Modelling & Software**, online, v. 24, n. 10, p. 1163-1170, 2009.

SYNGENTA FOUNDATION. **About Kilimo Salama**. Disponível em: <<https://kilimosalama.wordpress.com/about/>> Acesso em 13 dez. 2016.

SWINDELL, J. E. G. Mapping the spatial variability in the yield potential of arable land through GIS analysis of sequential yield maps. In: STAFFORD, J. V. (Ed.). **Precision Agriculture**. Oxford: BIOS Scientific Publishes Ltd, 1997. p. 827-834.

USFM – Universidade Federal de Santa Maria. **CR Campeiro 7**. Disponível em: <[82TTP://www.crcampeiro.net/](http://www.crcampeiro.net/)>. Acesso em 13 dez. 2016.

XIANG, L.; YU-CHUN, P.; ZHONG-GIANG, G.; CHUN-JIANG, Z. Delineation and Scale Effect of precision agriculture management zones using yield monitor data over four years. **Agriculture Sciences in China**, Pequim, v. 6, n. 2, p. 180-188, 2007.

8 CONSIDERAÇÕES FINAIS

8.1 Conclusões

No processo de geração de ZMs deve-se considerar a importância de todas as etapas e é de fundamental importância a escolha de variáveis que reflitam o resultado do potencial produtivo da área, assim como que a coleta de tais variáveis possa ser cada vez mais viabilizada para o produtor. Além da escolha das variáveis é importante que se busque utilizar os melhores métodos para geração de tais ZMs, como a escolha do melhor interpolador (SCHENATTO et al. 2016), o melhor método de normalização das variáveis, métodos adequados para geração do processo de agrupamento, além de índices confiáveis de avaliação.

Nesse trabalho foi realizado o estudo de alguns pontos ligados ao processo de geração de ZMs e buscou-se viabilizar a coleta da nova variável proposta, com o objetivo de, ligado a outros trabalhos, fornecer aos pesquisadores e produtores uma forma confiável para a geração de ZMs, por se tratar de um processo com muitas etapas que exercem influências distintas no processo.

Com o estudo realizado no primeiro artigo, verificou-se que, no processo de geração de ZMs utilizando o algoritmo de agrupamento Fuzzy C-Means, quando se faz uso de mais de uma variável, os métodos de normalização exercem influência no processo de clusterização, gerando mapas de zonas de manejo diferentes quando comparados entre si e quando comparados com os mapas gerados sem o uso de nenhuma técnica de normalização. Quando utilizada somente uma variável não houve diferença nos mapas gerados quando não aplicado ou aplicado qualquer método de normalização, devido à escala da variável, nesse caso, não exercer influência no processo, por se tratar de uma única escala de valores. Quando utilizada mais de uma variável, o método de normalização pela amplitude apresentou melhores resultados segundo os índices de avaliação utilizados, indicando que os dados de produtividade foram melhor separados entre as zonas geradas.

O estudo realizado no segundo artigo mostrou que a utilização da variável experiência do produtor para definir ZMs pode ser uma ferramenta eficiente e simples, além de diminuir os custos no processo de definição de ZMs, quando comparado ao método tradicional de utilização de variáveis estáveis do solo e do relevo.

Com a comprovação da eficiência na utilização da variável experiência do produtor, foi criado um software aplicativo para dispositivos móveis que permite auxiliar o produtor na definição dessa variável e, assim, utilizá-la na geração de ZMs juntamente com outras variáveis do solo disponíveis, podendo fazer uso de tais ZMs para direcionar futuras amostragens de solo.

O software desenvolvido AgData-Mobile também possibilita uma fácil e amigável ferramenta mobile de registro e gerenciamento das informações de operações de campo, permitindo ao produtor utilizá-la em substituição de planilhas de controle de dados de campo, ou, se ainda não realiza o registro dessas informações, passar a armazená-las. Tais informações fornecem dados para consultas e estudos futuros, com o intuito de direcionar uma forma de cultivo com maior gerenciamento das informações de campo.

A gratuidade do software permitirá que os produtores tenham acesso fácil a essa ferramenta e possam utilizá-la.

8.2 Trabalhos futuros

Na questão de geração de ZMs é importante que cada vez se busque estudar os métodos mais adequados nas diferentes etapas desse processo, haja vista que cada etapa exerce um papel fundamental no processo e decisões inadequadas podem levar a resultados completamente distintos da realidade dos talhões.

A variável experiência do produtor merece uma atenção dos pesquisadores devido à riqueza de informação que o produtor possui de sua área e investigar fatores históricos pode levar a descobertas antes não avaliadas. Sugere-se que essa variável seja avaliada em outras áreas experimentais e em diferentes culturas e condições de cultivo, mas não descartando as variáveis estáveis do solo já utilizadas na geração de ZMs.

Como trabalhos futuros ligados ao software, pretende-se integrar nessa ferramenta o controle da parte financeira das operações de campos, que compreendem dados ligados a custos com aplicação de insumos, máquinas, operador e também a renda gerada a cada safra. Esse controle financeiro permitirá, também futuramente, implementar um módulo com análise de lucro e lucratividade.

APÊNDICES

APÊNDICE A – TUTORIAL E DESCRIÇÃO DO SOFTWARE AGDATA-MOBILE

O software para dispositivos móveis AgData-Mobile consiste em um software para gerenciamento de informações de campo que utiliza tecnologias livres e armazenamento em nuvem. Para o funcionamento correto das funcionalidades do aplicativo é necessário que o dispositivo móvel possua no mínimo a versão 4.1 (Jelly Bean) do Android e a plataforma Android 6.0 (Marshmallow), que corresponde à última versão disponível no início do processo de desenvolvimento (fevereiro de 2016).

A seguir são descritas as funcionalidades e as instruções de uso do software:

1. CADASTRO DE USUÁRIOS E TELA DE LOGIN

Após instalar o aplicativo ADF Mobile (AgData-Mobile) a primeira tela a ser visualizada é a tela de login (Figura 1). Caso o usuário já possua um cadastro em um dos softwares da plataforma AgData, basta digitar o email e a senha e clicar no botão **Entrar** para ter acesso ao menu inicial do aplicativo.

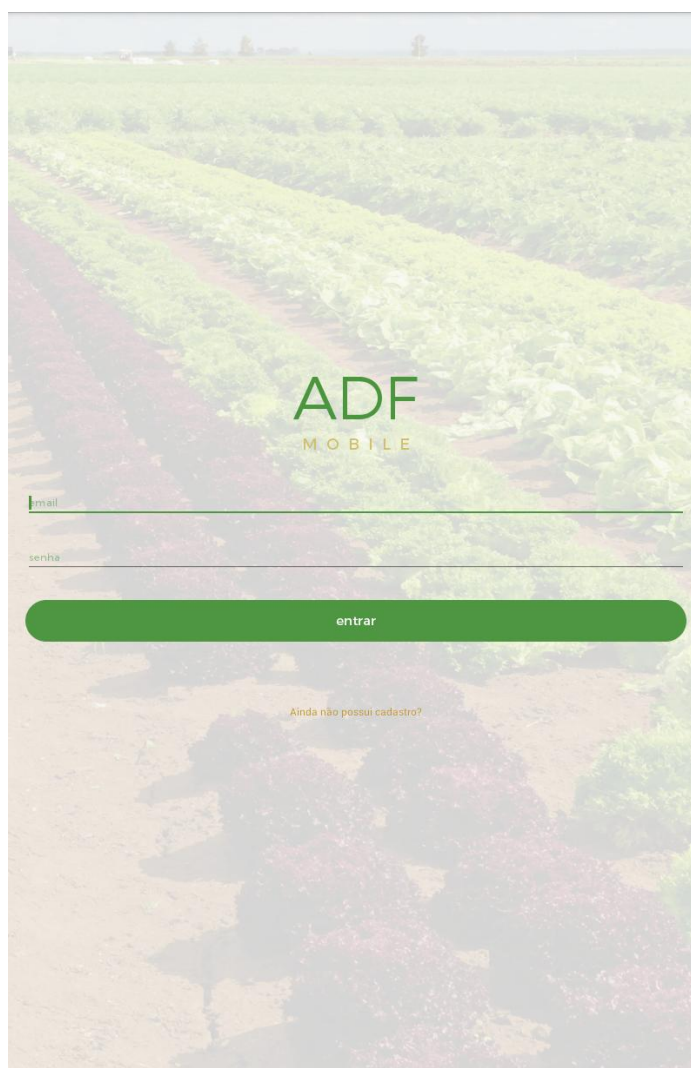


Figura 1 Tela de login para ter acesso as funcionalidades do ADF Mobile (AgData-Mobile)

Se o usuário ainda não possuir um cadastro, este deve clicar na opção **Ainda não possui cadastro?** e será encaminhado para a tela de cadastro de novo usuário (Figura 2). É preciso informar nome, email, senha e uma confirmação da senha para efetuar o cadastro e, após isso, clicar na opção **Enviar**.

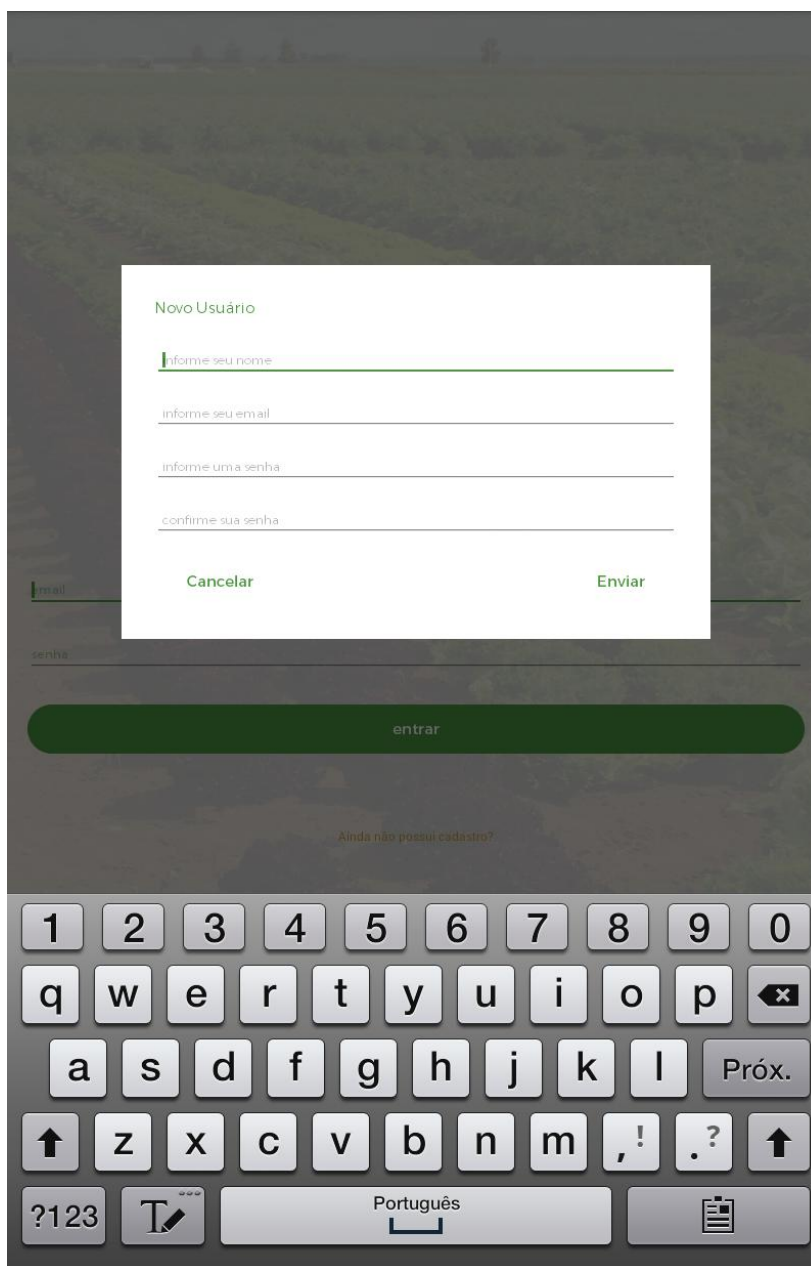


Figura 2 Tela de cadastro de usuário

Após realizado o cadastro, será apresentado ao usuário o menu inicial com as funcionalidades disponíveis na aplicação (Figura 3). Perceba que o nome do usuário logado na aplicação aparecerá no canto superior esquerdo da tela.

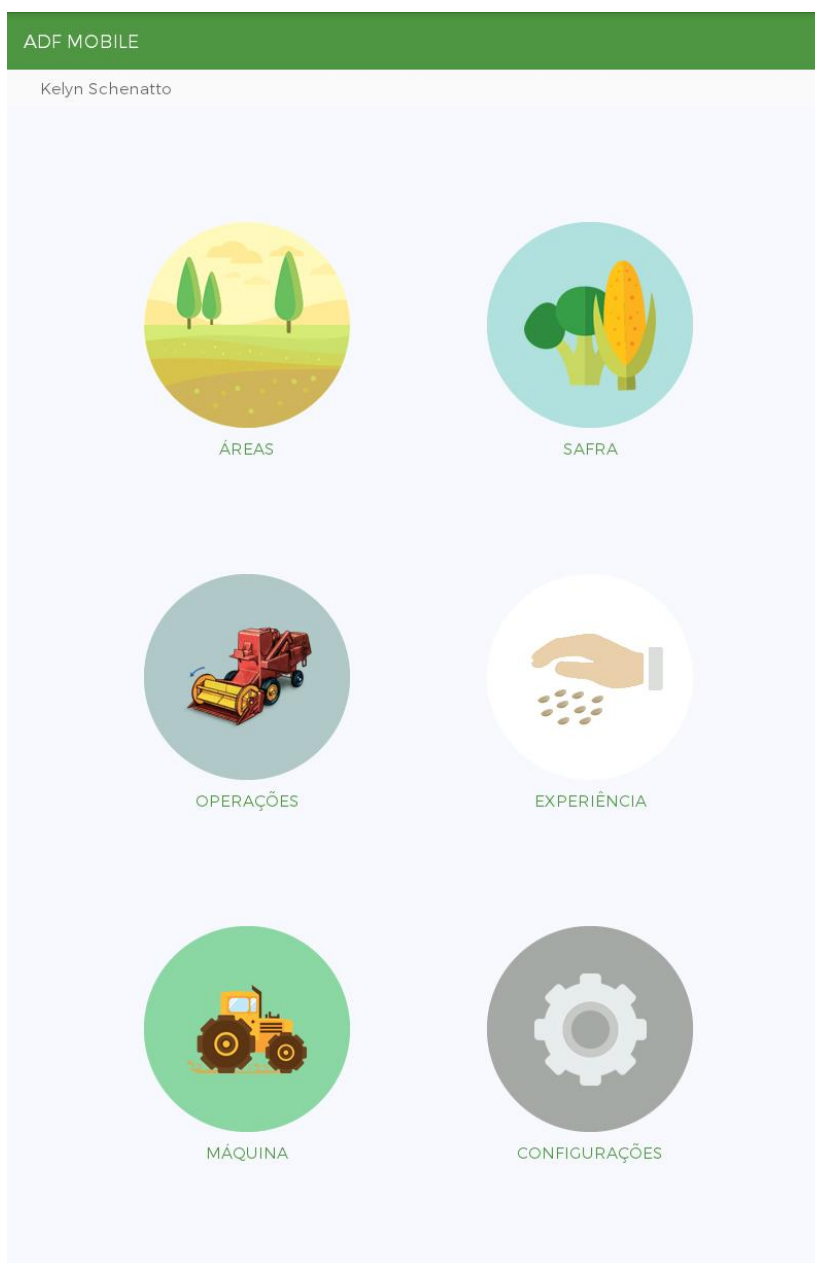


Figura 3 Menu inicial do aplicativo AgData-Mobile

1.1 Trocar usuário

Caso haja necessidade, para trocar de usuário é preciso acessar a opção **Configurações** no menu inicial e clicar na opção **Trocar usuário** (Figura 4).

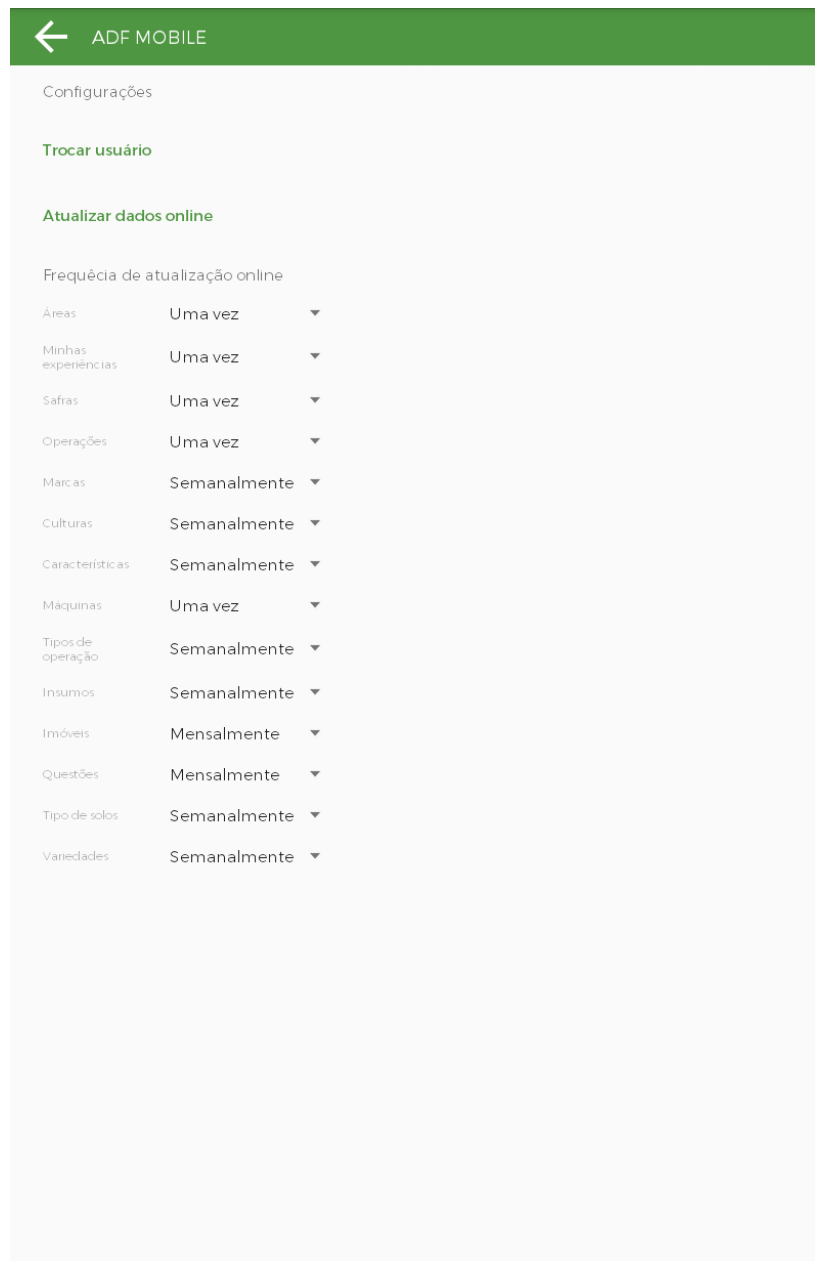


Figura 4 Trocar usuário

Se o usuário possui dados ainda não salvos no servidor será solicitado que os dados sejam enviados (**Enviar Dados**), caso contrário ele pode clicar na opção **Continuar mesmo assim** e será direcionado novamente para a tela de login (Figura 1). É importante prestar atenção nessa informação e enviar os dados para o servidor para que não haja perda dos dados armazenados apenas localmente.

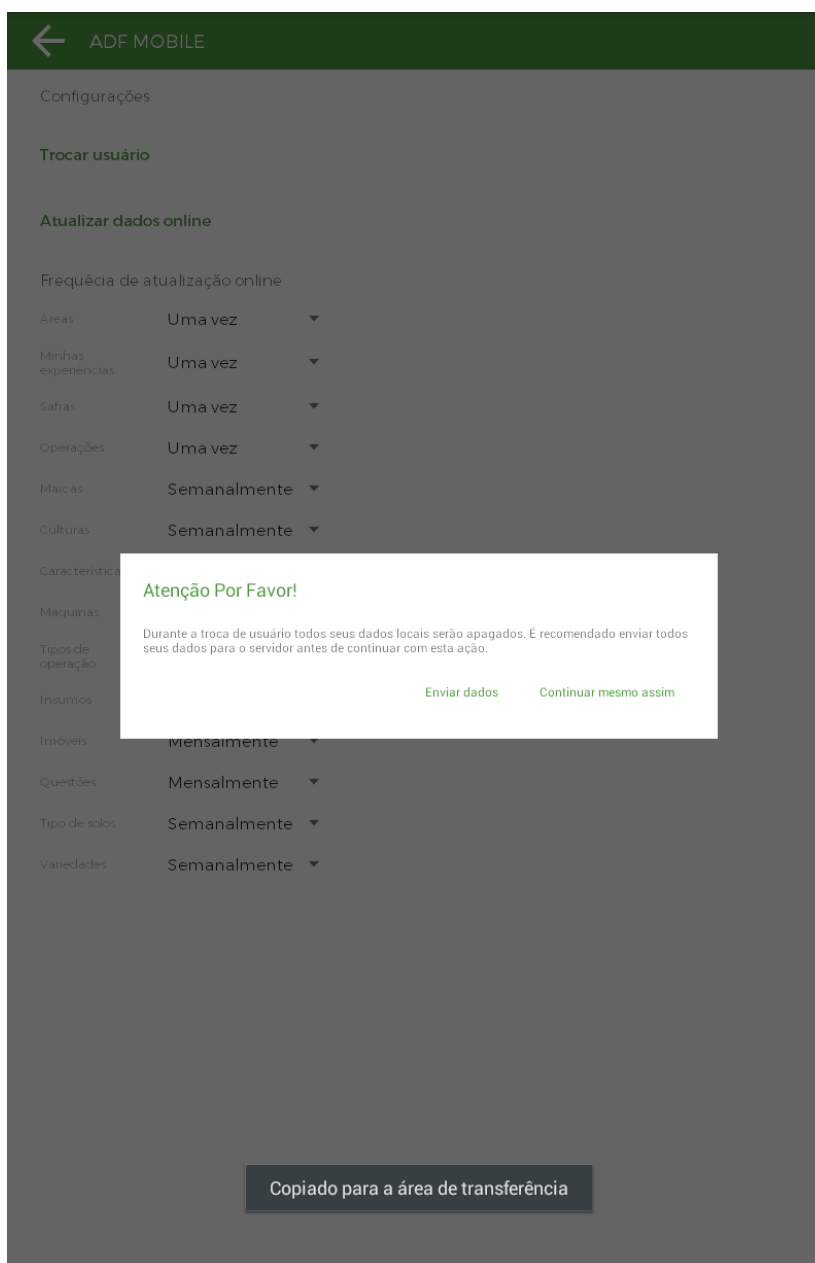


Figura 5 Troca de usuário

2. CADASTRO DE ÁREA

Para realizar o cadastro de uma área é preciso clicar no menu inicial (Figura 3) no ícone **Áreas**. Ao acessar essa opção será apresentada uma tela de gerenciamento de áreas (Figura 6), onde poderão ser visualizadas as áreas já cadastradas (caso o usuário já tenha cadastrado alguma área) com as opções de visualizar, editar e excluir cada área.

O usuário também pode cadastrar uma nova área clicando na opção **Nova Área**.




Figura 6 Tela de gerenciamento de áreas

Ao clicar na opção **Nova Área** (Figura 6), o usuário deve informar um nome para a área que deseja cadastrar (Figura 7) e, em seguida, aparecerão as opções de seleção do tipo de solo da área, qual o proprietário e qual o modo de captura dos pontos que formarão o contorno da área. O usuário pode optar pelo modo de **Locomoção GPS**; dessa forma ele deve percorrer todo o contorno do talhão para realizar a captura da área ou ainda optar pela captura por meio de **Toque na Tela**, em que o usuário definirá o contorno manualmente na tela do dispositivo móvel.

The screenshot shows the 'Novo área' (New area) screen in the ADF MOBILE application. At the top, there is a green header with a back arrow and the text 'ADF MOBILE'. Below the header, the text 'Nova área' is displayed, followed by a text input field containing 'Tasca - sede'. The main content area is white and contains several sections: 'Latossolo distroferrico vermelho' with a dropdown arrow, 'Imovel - Aldo' with a dropdown arrow, and 'Método de captura de pontos' (Point capture method) with two radio button options: 'Locomoção GPS' and 'Toque na tela'. Below these options is a large, empty light gray area labeled 'Tamanho da área' (Area size) on the left and 'hectares' on the right. A green 'Salvar' (Save) button is positioned in the bottom right corner of the form.


Figura 7 Cadastro de nova área

Assim que o usuário clicar no modo de captura da área o aplicativo indicará o local em que o usuário se encontra (Figura 8). É provável que no momento da captura da área o usuário esteja em um local próximo da área; caso isso não se aplique, ele deve percorrer a tela até chegar no local da área a ser definida.




Figura 8 Localização do dispositivo móvel em que o aplicativo está instalado


Depois de localizar a área a ser definida (Figura 9a), o usuário deve clicar em **Iniciar modo captura** (Figura 9a) e ir selecionando os pontos (Figuras 9b e 9c) até formar o contorno da área (Figura 9d).




a) Localização da área



b) Definição do contorno da área



c) Definição do contorno da área



d) Finalização do contorno da área

Figura 9 Definição do contorno da área

Ao fechar o contorno da área o usuário é encaminhado novamente para a tela de **Cadastro de área** (Figura 10), onde aparecerá a informação de que os pontos foram

capturados com sucesso. No campo tamanho da área será mostrada a informação da área do talhão em hectares. O usuário deve clicar na opção **Salvar** para salvar as informações da área definida.

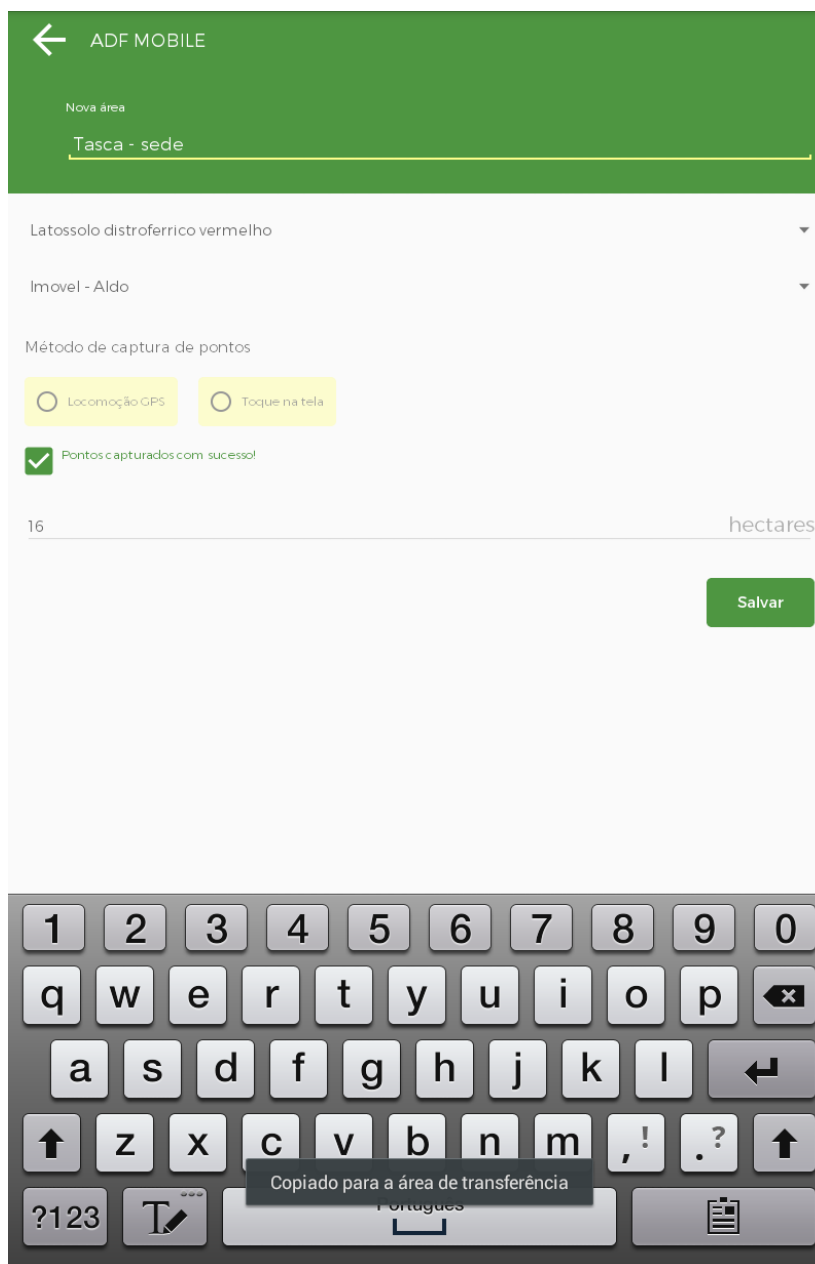


Figura 10 Tela de cadastro de área

3. CADASTRO DE SAFRA

Para acessar a tela de gerenciamento de safras, o usuário deve clicar no ícone **Safras** na tela do menu inicial do aplicativo (Figura 3). Ao acessar a tela de gerenciamento de safras (Figura 11), o usuário poderá visualizar, editar ou excluir as safras já cadastradas ou então cadastrar uma nova safra, clicando no botão **Nova Safra**.




Figura 11 Tela de gerenciamento de safras

Ao clicar em **Nova Safra** o usuário é encaminhado para a tela de cadastro de safras (Figura 12), onde ele deve definir um nome para nova safra a ser cadastrada, a data de início da safra e a cultura a ser plantada e clicar na opção **Salvar**.

ADF MOBILE

Nova safra

Safra soja 2016 -2017

Início


16	Set	2015
17	Out	2016
18	Nov	2017

Soja

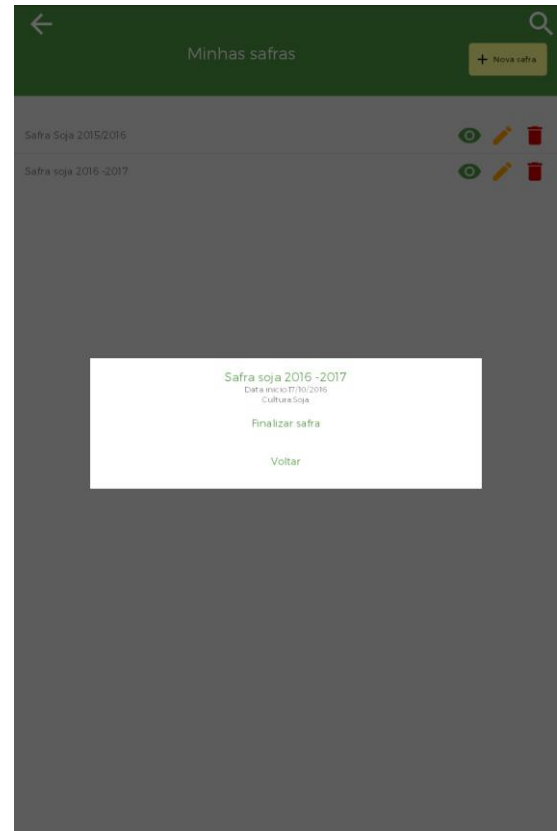
Salvar

Figura 12 Tela de cadastro de safra

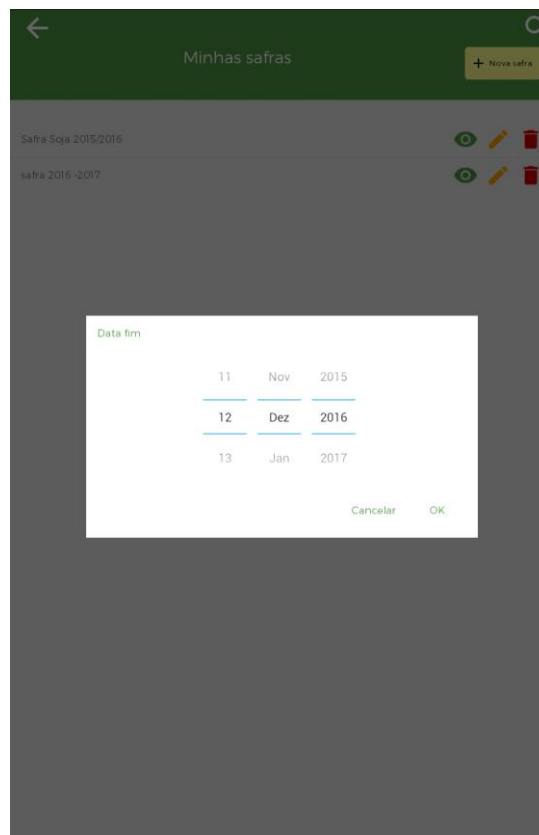
Após salvar os dados da safra ela aparecerá na lista de safras cadastradas pelo usuário (Figura 13a), e este pode optar por visualizar os dados da safra salva, sendo que nesse caso aparecerão os dados da safra e a opção **Finalizar safra** (Figura 13b). Ao clicar em **Finalizar safra** será mostrado ao usuário a opção de selecionar a data de fim da safra (Figura 13c), que corresponde à data da colheita da cultura.



a) Lista de safras cadastradas



b) Visualizar dados da safra



c) Data de fim da safra

Figura 13 Visualização das safras salvas e opção de finalizar safra

4. CADASTRO DE OPERAÇÕES

O cadastro de operações compreende o registro de operações de campo realizadas durante cada safra em uma determinada área agrícola. Para acessar a opção de cadastro de operações o usuário deve clicar no ícone **Operações** no menu inicial (Figura 3).

Ao acessar a tela de cadastro de operações (Figura 14a) o usuário deve selecionar o **Talhão** e a **Safra** para os quais deseja registrar uma operação de campo. Para cada tipo de operação selecionada são apresentadas opções diferentes relacionadas às necessidades de cada operação (Figura 14b).

Figure 14 consists of two screenshots of a mobile application interface. Screenshot (a) shows the 'Operações' screen with a dropdown menu for selecting a crop cycle ('Safra'). Screenshot (b) shows the 'Safra Soja 2015/2016' screen with a date picker for 'Data inicio' and 'Data fim', and a dropdown menu for selecting the type of operation.

a) Tela de registro de operações

b) Seleção do tipo de operação

Figura 14 Registro de operações

Na Figura 15 pode-se visualizar o registro de uma operação de plantio, onde deve ser realizada a inserção de dados referentes ao **Tipo de semente** e à **Quantidade** semeada (Figura 15a), o registro dos **Insumos** e **Quantidades** aplicadas (adubação) (Figura 15b) e quais **Máquinas** foram utilizadas nessa operação (Figura 15c).

a) Seleção da variedade de semente

b) Seleção do insumo e quantidade

c) Seleção das máquinas utilizadas

Figura 15 Registro de operação de plantio

Na Figura 16 é apresentado um novo exemplo, nesse caso do registro de operação de **Pulverização** (Figura 16a), onde devem ser inseridos dados referentes aos **Insumos**

aplicados e qual a **Máquina** que realizou essa operação. Também é mostrado um exemplo de registro de operação de **Colheita** (Figura 16b), onde deve-se registrar também os dados referentes à **Entrega do produto**, como em qual **Armazém** o produto foi entregue, o **Rendimento** e a **Umidade**, além de um campo para possíveis **Observações**.

a) Operação de pulverização

b) Operação de colheita

Figura 16 Exemplo de registro de operações

5. CADASTRO DE EXPERIÊNCIA DO PRODUTOR

Para acessar a tela de gerenciamento de experiências, o usuário deve clicar no ícone do menu inicial **Experiências** (Figura 3). Ao acessar essa opção, o usuário deve selecionar referente a qual talhão ele deseja visualizar ou registrar experiências (Figura 17). O usuário pode visualizar, editar ou excluir as experiências ou clicar no botão **Nova experiência** para cadastrar uma nova experiência

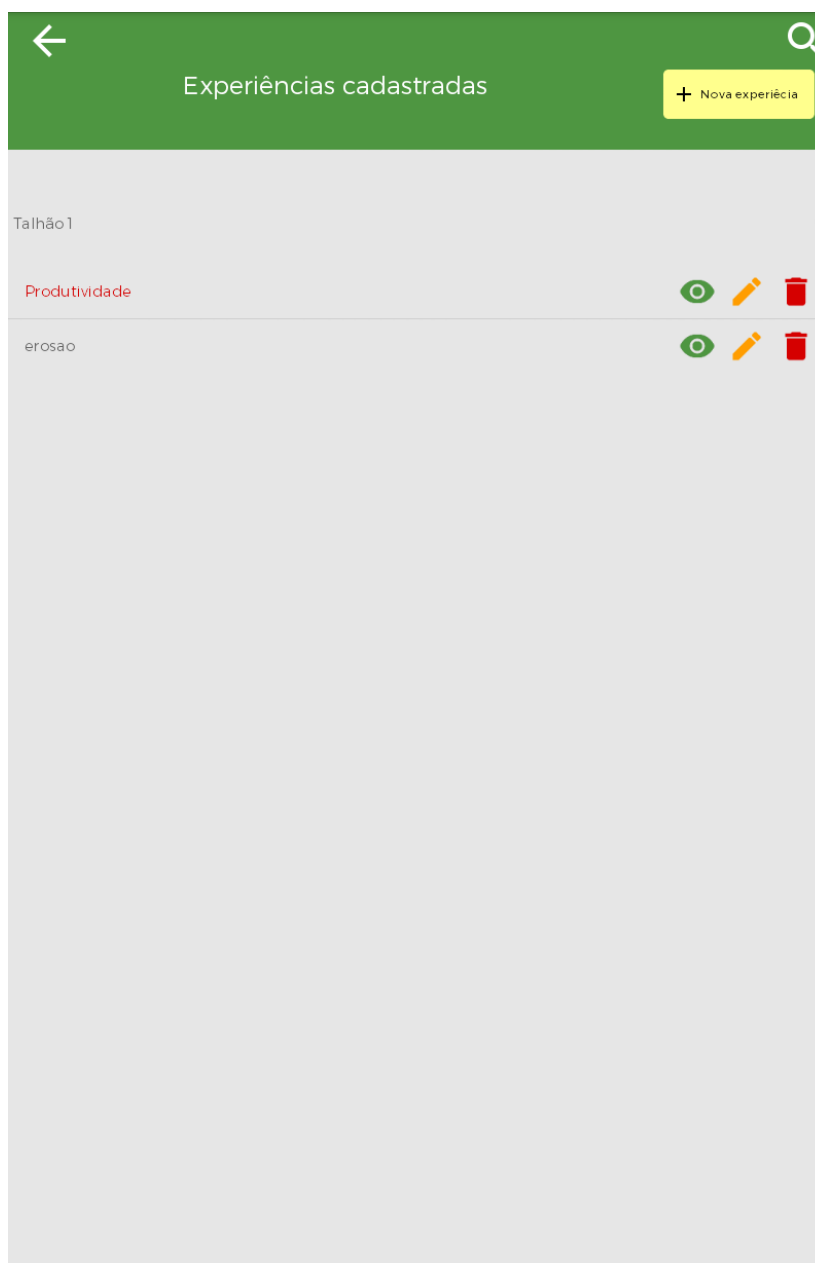


Figura 17 Tela de gerenciamento de experiências

Na tela de cadastro de novas experiências (Figura 18) o usuário deve informar uma **Descrição** da experiência, o **Tipo** da experiência (ex. potencial de produtividade) a **Data** em que ela foi registrada, sendo que o software oferece como sugestão a data atual. Além disso, o usuário deve selecionar qual o talhão em que deseja registrar a experiência e o método de captura dos pontos, se por **Locomoção GPS** ou **Toque na tela**.

ADF MOBILE

Nova experiência

Produtividade

Potencial de produtividade

Data

11	Nov	2015
12	Dez	2016
13	Jan	2017

Talhão 1

Capturar pontos

Locomoção GPS Toque na tela

Responder questionário

Salvar

Figura 18 Tela de registro de experiências

Após a seleção do método de captura dos pontos o usuário é redirecionado ao local da área experimental (Figura 19a), podendo percorrer a área capturando os pontos pelo método de caminhada ou por meio da seleção na tela do celular.

O usuário deve definir as faixas de **Produtividade** (Figura 19b), podendo dividir a área por exemplo em faixas de produtividade baixa, média e alta, inserindo os valores estimados de produtividade para cada faixa de área (Figura 19c).

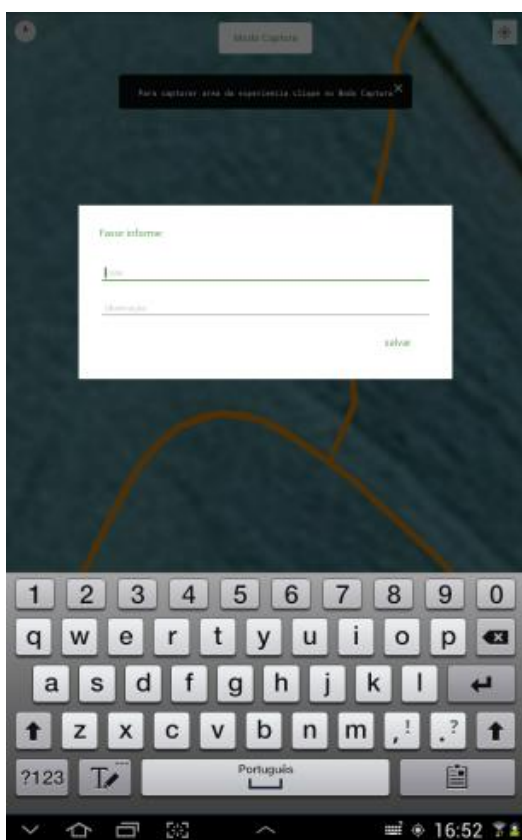
Ao finalizar o registro das zonas de produtividade, a experiência do produtor é registrada e fica armazenada no banco de dados da aplicação.



a) Visualização da área escolhida



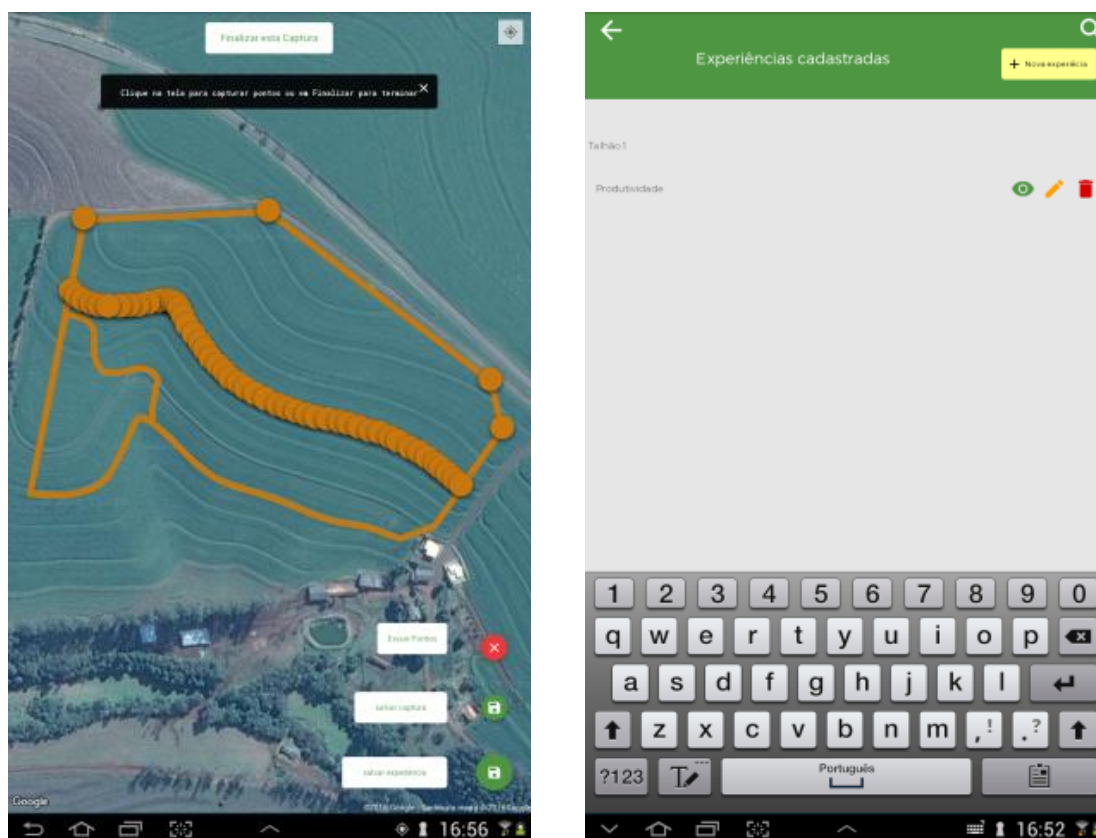
b) Definição da primeira faixa de produtividade



c) Definição dos valores de produtividade



d) Visualização da classe de produtividade



f) Definição da terceira classe de produtividade g) Experiência registrada

Figura 19 Registro da variável experiência do produtor