WAGNER ROGÉRIO FERREIRA PINHEIRO

AVALIAÇÃO DE KRIGAGENS ATRAVÉS DE INDICADORES LOCAIS PARA A AGRICULTURA DE PRECISÃO

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Estatística Aplicada e Biometria, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS, BRASIL
2013

Ficha catalográfica preparada pela Seção de Catalogação e Classificação da Biblioteca Central da UFV

T
P654a
2013

Pinheiro, Wagner Rogério Ferreira, 1985-
Avaliação de krigagens através de indicadores locais para a agricultura de precisão / Wagner Rogério Ferreira Pinheiro. – Viçosa, MG, 2013.
ix, 67f. : il. (algumas color.) ; 29cm.

Inclui anexos.
Orientador: Gérson Rodrigues dos Santos.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 53-57.

1. Geologia - Métodos estatísticos. 2. Análise espacial (Estatística). 3. Agricultura de precisão. 4. Sistemas de informação geográfica. 5. Geologia - Processamento de dados. 6. Mapas de zoneamento. I. Universidade Federal de Viçosa. Departamento de Estatística. Programa de Pós-Graduação em Estatística Aplicada e Biometria. II. Título.

CDD 22. ed. 519.5

WAGNER ROGÉRIO FERREIRA PINHEIRO

AVALIAÇÃO DE KRIGAGENS ATRAVÉS DE INDICADORES LOCAIS PARA A AGRICULTURA DE PRECISÃO

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Estatística Aplicada e Biometria, para obtenção do título de *Magister Scientiae*.

APROVADA: 28 de fevereiro de 2013.

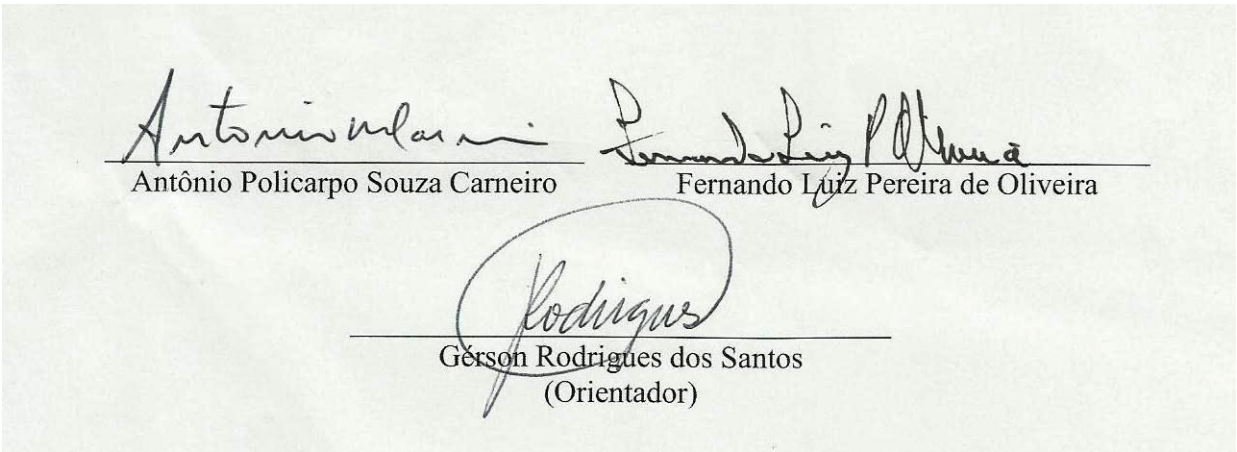

Penso no que faço, com fé. Faço o que devo fazer com amor. Eu me esforço para ser cada dia melhor, pois bondade também se aprende. Mesmo quando tudo parece desabar, cabe a mim decidir entre rir ou chorar, ir ou ficar, desistir ou lutar. Porque descobri, no caminho da vida que o mais importante é decidir.

Cora Coralina.

A Deus, meus familiares e amigos.

AGRADECIMENTOS

Agradeço a Deus por sempre fazer com que eu perceba a sua presença em todos os dias de minha vida nos momentos mais felizes ou mais tristes. Aos meus avós, Epitaciano Ferreira e Maria Enoi Ferreira pelo empenho, dedicação e incentivo dispensados ao longo de minha vida. A minha mãe Ângela Pinheiro e minha irmã Giselly Pinheiro que sempre acreditaram em mim e incentivaram minhas decisões. Aos meus familiares mais próximos, em especial a minha prima Nelly Ferreira e minha tia Anilce Ferreira.

Agradeço a todos os professores do Programa de Pós-Graduação em Estatística Aplicada e Biometria da Universidade Federal de Viçosa – UFV, pelos ensinamentos que aqui me transferiram. Em especial ao meu orientador Gerson Rodrigues dos Santos que teve um papel significativo nessa fase da minha formação acadêmica, me ensinando não somente com suas explicações e orientações, mas, também com exemplos dia após dia, além da colaboração, incentivo, generosidade, compreensão e firmeza com que norteou meus estudos.

Agradeço as secretárias Anita Paiva e Carla Zinato pela diligência, eficiência, zelo e atenção dedicados a mim nas horas em que as solicitei. Não posso deixar de registrar aqui meus agradecimentos, mais que especiais, aos amigos afetuosos de todas as horas por todas as experiências vividas em Viçosa. Agradeço imensamente a vocês estimados amigos Renata Maciel, Camila Azevedo, Lidiane Ferreira, Cássio dos Reis, Bruno Caetano e Diego Paiva, com atenção especial à Maria de Fátima Almeida. Agradeço ainda ao Wellington que foi peça fundamental no processo de elaboração desse trabalho. Muito obrigado, vocês são pessoas iluminadas.

Com um carinho todo especial agradeço a família Figueira primeiramente na pessoa de minha amiga e irmão Priscila Figueira pelo privilégio de ter permitido que eu fizesse parte de sua vida. Agradeço ainda, sua Darcirene Figueira e seu Pai José Maria Figueira, por toda a compreensão, atenção, cuidado e carinho que me proporcionaram. Meus sinceros agradecimentos.

Agradeço aos membros da banca Antônio Policarpo Souza Carneiro e Fernando Oliveira pela contribuição destinada a este trabalho permitindo com que se tornasse concreta a obtenção do título de *Magister Scientiae*. Por fim, agradeço a todos que de alguma forma contribuíram, direta ou indiretamente para a realização deste trabalho. Muito obrigado.

SUMÁRIO

LISTA DE TABELAS vi
LISTA DE FIGURAS vii
RESUMO viii
ABSTRACT ix
1. INTRODUÇÃO 1
2. REFERENCIAL TEÓRICO 5
2.1 O uso da informação espacial na agricultura 5
2.1.1 Agricultura de Precisão (AP) 6
2.1.2 O mapa e sua importância na agricultura 7
2.2 Sistema de Informações Geográficas (SIG) 8
2.2.1 Imagem *Raster* 9
2.3 Funções algébricas de mapas 12
2.3.1 Álgebra de mapas 13
2.4 Exatidão ou acurácia de mapas 15
2.4.1 Matriz de confusão ou de erros 16
2.4.2 Índice Kappa 18
2.5 Geoestatística 20
2.5.1 Semivariograma 21
2.5.2 Modelos teóricos de Semivariograma 23
2.5.3 Índice de dependência espacial 25
2.5.4 Krigagem 26
2.5.5 Validação cruzada 28
2.6 Relações bidimensionais 29
3. MATERIAL E MÉTODOS 32
3.1 Simulações 32
3.2 Recursos Computacionais 34
3.3 Comparação entre os mapas temáticos 35
4. RESULTADOS E DISCUSSÃO 37
4.1 Análise exploratória 37
4.2 Ajuste do semivariograma experimental 38
4.3 Validação 42
4.4 Mapas temáticos 44
4.5 Comparação entre os mapas temáticos obtidos 48
5. CONCLUSÕES 52
6. REFERÊNCIAS BIBLIOGRÁFICAS 53
ANEXOS 58

LISTA DE TABELAS

Tabela 1: Representação matemática de uma matriz de confusão. 17

Tabela 2: Índice Kappa e o correspondente desempenho da classificação. 19

Tabela 3: Descrição da malha amostral (*Grid*), dos parâmetros e modelos utilizados nas simulações de dados.....33

Tabela 4: Medidas estatísticas dos dados simulados para os diferentes *grids* (50×50, 100×100 e 150×150) e estrutura de dependência espacial. 38

Tabela 5: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com fraca DE e diferentes grids. 38

Tabela 6: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com moderada DE e diferentes grids. 40

Tabela 7: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com forte DE e diferentes grids. 41

Tabela 8: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com fraca DE e diferentes grids 43

Tabela 9: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com moderada DE e diferentes grids 43

Tabela 10: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com forte DE e diferentes grids.....44

Tabela 11: Índice Kappa ($\hat{\kappa}$) de concordância, correlação global (r_g) e *p*-valor segundo grid de amostragem e estrutura de dependência espacial. 48

LISTA DE FIGURAS

Figura 1: Representação gráfica de um mapa rasterizado. [Fonte: Adaptado de ARCGIS, 2012].....10

Figura 2: Representação gráfica da codificação de um mapa de polígonos para um mapa raster. [Fonte: Adaptado de ARCGIS, 2012] 11

Figura 3: Representação gráfica de como se realiza a localização dos pixels no mapa raster. [Fonte: Adaptado de ARCGIS, 2012] 12

Figura 4: Representação das operações aritméticas pixel a pixel executadas em diferentes bandas. [Fonte: Adaptado de Meneses *et al*. 2012] 14

Figura 5: Representação gráfica de um caso hipotético onde atua a geoestatística e a estatística clássica.....20

Figura 7: Representação gráfica de um semivariograma e seus parâmetros Alcance (*a*), Efeito Pepita (C_0), Contribuição (C_1) e Patamar ($C = C_0 + C_1$).....23

Figura 6: Representação dos modelos de semivariogramas usualmente utilizados (Esférico, Guassiano e Exponencial). 25

Figura 8: Escala de correlação linear entre variáveis. [Fonte: Adaptado de Ramos *et al*. 2013].....30

Figura 9: Esquema esperado para relação de concordância entre mapas. 31

Figura 10: Semivariogramas experimentais e modelos ajustados para os dados com fraca DE.....39

Figura 11: Semivariogramas experimentais e modelos ajustados para os dados com moderada DE. ...40

Figura 12: Semivariogramas experimentais e modelos ajustados para os dados com forte DE. 41

Figura 13: Mapas temáticos para o *grids* de 50×50 e diferente estrutura de dependência espacial (Fraca, moderada e forte).....45

Figura 14: Mapas temáticos para o *grid* de 100×100 e diferente estrutura de dependências espacial (Fraca, moderada e forte).....46

Figura 15: Mapas temáticos para o grid de 150×150 e diferente estrutura de dependências espacial (Fraca, moderada e forte).....47

Figura 16: Representação esquemática para a obtenção da correlação local (r_i) entre mapas temáticos. 49

Figura 17: Mapas de correlação local, em diferentes grids, para a comparação entre os mapas temáticos no caso com fraca dependencia espcial.....51

Figura 18 Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 50×50. 65

Figura 19: Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 100×100.....66

Figura 20: Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 150×150.....67

RESUMO

PINHEIRO, Wagner Rogério Ferreira, M.Sc., Universidade Federal de Viçosa, fevereiro de 2013. **Avaliação de krigagens através de indicadores locais para a agricultura de precisão.** Orientador: Gérson Rodrigues dos Santos. Coorientadores: Nerilson Terra Santos e Antônio Policarpo Souza Carneiro.

O agronegócio abrange uma vasta cadeia de atividades produtivas. Pode-se destacar como uma das atividades deste ramo a agricultura de precisão que se vale frequentemente de informações georreferenciadas para descrever por meio de mapas a variabilidade espacial de determinadas áreas. Uma técnica que apresenta relevada importância para este contexto é a Geoestatística, pois proporciona a obtenção de mapas temáticos, considerando a estrutura de dependência espacial do fenômeno em estudo. Assim este estudo apresenta um procedimento para identificar subáreas destinadas ao plantio considerando a dependência espacial da variável de interesse sem a necessidade de categorização. Para tanto são abordadas metodologias de álgebra de mapas com a intenção de incorporar medidas de associação estatística de forma local. Desde modo, foi utilizado o método de Krigagem Ordinária presente na Geoestatística e para medir a concordância dos mapas temáticos utilizou-se o índice Kappa e a coeficiente de correlação linear global e local. Como resultados principais pode-se destacar que a concordância entre os mapas de forma localizada evidencia que os modelos de dependência espacial utilizados na Krigagem Ordinária exercem influência local na definição dos mapas temáticos utilizados na agricultura de precisão, aspecto esse que não é captado se utilizadas (para o caso agrícola), codificações dos valores interpolados (zonas de manejo) e destas extrair-se índices globais de concordância.

ABSTRACT

PINHEIRO, Wagner Rogério Ferreira, M.Sc., Universidade Federal de Viçosa, February, 2013. **Evaluation krigings by means of local indicators for precision agriculture.** Advisor: Gérson Rodrigues dos Santos. Co-Advisor: Nerilson Terra Santos and Antônio Policarpo Souza Carneiro.

Agribusiness covers a vast chain of production activities. Can be noted as one of the activities of this branch precision agriculture that relies often georeferenced information to describe through the spatial maps of certain areas. One technique that has high importance in this context is the Geostatistics, it provides obtaining thematic maps, considering the spatial dependence structure of the phenomenon under study. So this study presents a procedure to identify subareas for planting considering the spatial dependence of the variable of interest without the need for categorization. For both methodologies are addressed map algebra with the intention of incorporating measures of statistical association locally. In this way, we used the method of ordinary kriging in this Geostatistics and to measure the agreement of thematic maps used the Kappa index and linear correlation coefficient global and local. As main results can be noted that the agreement between the maps of localized form performed by Pearson's correlation shows that the spatial dependence models used ordinary kriging in place exerts influence in defining the thematic maps used in precision agriculture, aspect one that is not picked up used (in case agricultural) encodings of interpolated values (management zones) and draw up these global indices of agreement.

1. INTRODUÇÃO

A agricultura entendida como um sistema produtivo é nomeada por Agronegócio ou *Agribusiness*. Este termo abrange as atividades agrícolas, pecuárias e florestais, compreendendo a produção de alimentos, fibras e energia. Segundo Batalha (2001), corroborado por Lourenço e Lima (2009), costuma-se dividir o agronegócio em três partes que podem, por sua vez, subdividir-se em outras atividades pontuais.

A primeira parte trata da execução agropecuária ou de "dentro da porteira" que representam o produtor rural de pequeno, médio ou grande porte. Na segunda parte, evidenciam-se os negócios à montante ou "da pré-porteira", e são representados pelas indústrias e comércios que fornecem insumos para a produção rural. Por fim, na terceira parte, estão os negócios à jusante, ou de "pós-porteira", que envolvem a compra, transporte, beneficiamento e venda dos produtos agropecuários, até chegar ao consumidor final (LOURENÇO e LIMA, 2009).

O agronegócio constitui um complexo conjunto de atividades abrangendo aspectos que vão desde o processo inicial de cultivo nas atividades envolvidas (agricultura, pecuária e florestal) até a distribuição e comercialização do produto final. Podendo, também, ser considerado como uma gama de relações comerciais efetuadas com produtos agrícolas envolvendo plantio, industrialização e comercialização daquilo que é cultivado.

Um dos componentes que apresenta relevada importância no agronegócio é o uso econômico e viável do solo, não apenas no sentido da sua composição química e orgânica, mas também geográfica. Na intenção de entender, por exemplo, como fatores relativos a composição de nutrientes e manejo adequado do solo, podem implicar na produtividade de determinado cultivo influenciando no modo com o qual se distribui, interage e se comporta espacialmente.

O estudo das características do solo desperta grande interesse científico e comercial, por permitir priorizar um gerenciamento de insumos de modo a definir o conjunto próprio de manejo, para que atenda às exigências de uma cultura específica utilizando, por exemplo, as sementes mais adequadas, o plantio mais indicado, prevenção a doenças e pragas, entre outros

aspectos próprios para o tipo de área que se dispõe. Tudo na intenção de utilizar o solo, destinado a determinado cultivo da maneira mais adequada.

Fraisse (1998) destaca que antes mesmo da revolução industrial e do processo de mecanização da atividade agrícola, os agricultores já se mostravam capazes de reconhecer a variabilidade espacial de certas características físico-químicas e biológicas das áreas cultivadas. Permitindo o emprego de esforços a áreas de menor ou maior fertilidade de maneira diferenciada.

Esse tipo de manejo, sistematizado segundo características observadas do solo, que era realizado antes mesmo de equipamentos de alta tecnologia, pode ser considerado também uma forma, embora empírica, de agregar maior precisão à atividade agrícola trazendo como consequência o aumento da produtividade da cultura na área destinada para plantio.

Conforme o exposto, identifica-se inicialmente, os conceitos que nortearam o que nas ultimas décadas definiu-se por Agricultura de Precisão que, de acordo com Ormond (2006), é um conjunto de técnicas de gerenciamento sistêmico e otimizado, para o enfoque agrícola, por meio do domínio da informação, com a utilização de uma série de tecnologias, tendo como base as informações sobre o posicionamento geográfico.

Este conjunto de ferramentas presentes na agricultura de precisão, frequentemente faz uso do GNSS (*Global Navigation Satelite System*), do SIG (*Sistema de Informações Geográficas*) que advém da tradução de *Geografical Information System* (GIS), de instrumentos e de sensores para medidas ou detecção de parâmetros ou de alvos de interesse no agroecossistema (solo, planta, insetos e doenças), de Estatística Espacial e da mecatrônica sendo, portanto, abrangente, sistêmico e multidisciplinar.

Câmara *et al.* (2000), evidencia que estes sistemas realizam o tratamento computacional de dados geográficos e manipulam a geometria e os atributos dos dados que estão georreferenciados, ou seja, localizados na superfície terrestre (num contexto agrícola, considera-se, a área destinada para o cultivo de determinada cultura) e representados numa projeção cartográfica, permitindo a captura, gerenciamento, análise, modelagem e visualização do comportamento das informações segundo a dependência espacial das mesmas.

No âmbito agrícola uma maneira amplamente utilizada de projeção cartográfica são os mapas temáticos que segundo Druck *et al*. (2004) descrevem a distribuição espacial de uma grandeza geográfica, expressa de forma qualitativa, como os mapas de pedologia e a aptidão agrícola de uma região. Estes dados, obtidos a partir de levantamento de campo, são inseridos no sistema por digitalização ou a partir de classificação de imagens. Em suma, a finalidade dos mapas temáticos é facilitar a navegação do usuário que procura informações sobre temas definidos.

Existem diversas formas de dependência para um determinado conjunto de dados, uma delas é a espacial. Das ciências que visão o tratamento sistemático dessa dependência no espaço, destaca-se a Estatística Espacial que condensa um extenso conjunto de técnicas capazes, dentre outros funções, de modelar a dependência de um evento de forma geográfica (DRUCK *et al*., 2004; CRESSIE, 1993; BAILEY e GATRELL, 1996).

Deste modo, conceitos pertencentes à Estatística Espacial apresentam grande contribuição no que tange as questões relativas à agricultura de precisão e consequentemente ao agronegócio. Desses conceitos, salienta-se o de exatidão ou acurácia das características espaciais contidos num mapa temático obtido por meio de um determinado processo de interpolação, captação de imagem de satélite, entre outros.

A exatidão ou acurácia dos mapas temáticos são uma forma de garantir mapas que nortearão decisões adequadas respeitando características próprias da área destinada ao cultivo agrícola. Essa etapa ocorre no processo inicial do agronegócio (“dentro da porteira”), onde se encontram também a agricultura de precisão, com a finalidade de obter mapas de fertilidade do solo que originarão referencias sobre a produtividade e consequentemente lucratividade da área.

Um índice muito utilizado em geoprocessamento para detectar a exatidão ou acurácia de mapas é o índice *Kappa*. Este índice retorna valores de referência da concordância entre mapas classificados segundo algum aspecto de interesse por meio dos *pixels* existentes na imagem. Porém, o índice *Kappa* não condensa qualquer outro tipo de informação a respeito da área ou método que originaram os mapas avaliados, como por exemplo, a dependência espacial que a área avaliada apresenta para a intensidade de uma variável de interesse.

Pode-se destacar como exemplo o estudo realizado por Batista (2012). Neste estudo foram comparados mapas temáticos de zonas de manejo por meio de diferentes modelos de dependência espacial. Batista (2012) conclui que os diferentes modelos não influenciam na definição do mapa temático, pois as krigagens foram similares (considerando zonas de manejo), segundo a estatística *Kappa* que apresentou para cada comparação índices superiores a 0,80 o que representa concordância muito boa de acordo com a Tabela de classificação de desempenho *Kappa*.

Assim, a necessidade de identificar pontualmente a comparação entre mapas temáticos se faz extremamente importante para a tomada de decisão dos responsáveis envolvidos no processo inicial do agronegócio. Uma alternativa válida para esse "problema" se origina dos mesmos elementos utilizados para o cálculo da estatística *Kappa*, os *pixels*. Os pixels apresentam boas características por permitirem o uso de álgebras das quais podem ser extraídas informações não somente globais (como no *Kappa*) mas também pontuais.

O presente trabalho parte da hipótese de que há uma relação algébrica que possa evidenciar os pixels, que neste contexto, representam áreas em menores porções que em por sua vez não são captadas em índices generalizados de concordância entre uma imagem de referência e uma classificada. Essas relações algébricas permitem obter estatísticas pontuais de similaridade entre os mapas. A intenção inicial do trabalho é de que haja uma relação "um para um" entre os pixels do mapa de origem e os do mapa classificado. Como objetivos específicos pode-se destacar:

- Identificar e comparar de forma global e local quadrantes que apresentam similaridade entre os mapas temáticos obtidos;
- Evidenciar as diferenças entre as krigagens de diferentes modelos de dependências espaciais;
- Obter mapas temáticos com maior detalhamento prestando suporte a tomada de decisão dos agentes envolvidos no sistema produtivo agrícola.

Para tanto, são abordadas metodologias de álgebra de mapas com a intenção de incorporar medidas de associação estatística de forma local. Deste modo, para os mapas temáticos a serem comparados, será utilizado o método de Krigagem Ordinária presente na Geoestatística.

2. REFERENCIAL TEÓRICO

Neste capítulo são apresentados os procedimentos metodológicos utilizados para análise espacializada no contexto agrícola. Com destaque para os principais conceitos do tema em estudo e as características das técnicas utilizadas com o devido rigor teórico.

2.1 O uso da informação espacial na agricultura

Câmara *et al*. (2007) evidenciam que na perspectiva moderna de gestão do território, toda ação seja de planejamento, ordenação ou monitoramento do espaço deve incluir a análise dos diferentes componentes de ambiente considerando o meio físico-biótico, a ocupação humana, e seu inter-relacionamento. No planejamento agrícola, essa abordagem é cada vez mais evidente.

São apontados por Câmara *et al*. (2007), pelo menos quatro grandes dimensões dos problemas ligados aos Estudos Ambientais que envolve também a agricultura, onde é grande o impacto do uso da tecnologia de Sistemas de Informação Geográfica, como o *Mapeamento Temático*, *Diagnóstico Ambiental*, *Avaliação de Impacto Ambiental* e *Ordenamento Territorial*. Destes, os mais utilizados na agricultura são os Mapeamentos Temáticos.

Os Mapeamentos Temáticos visam caracterizar e descrever a organização do espaço, como base para que sejam estabelecidas ações e estudos futuros. Esses levantamentos temáticos, a exemplo: os levantamentos geológicos, geomorfológicos, de solos, de cobertura vegetal, entre outros. Recebem relevada importância na agricultura. Porém, para que esses estudos sejam realizados de forma adequada, necessita-se de uma abordagem de geoprocessamento que combine ferramentas de análise espacial, processamento de imagens, Geoestatística e modelagem numérica de terreno (CÂMARA *et al*., 2007).

Atualmente, no agronegócio, o conjunto de métodos utilizados na área destinada ao plantio é o que se designa por Agricultura de Precisão que se vale do gerenciamento localizado de sistemas agrícolas. Do ponto de vista ambiental, a racionalização e a redução do uso de insumos são, segundo Antuniassi (1999), avaliados como um dos principais benefícios

oriundos da agricultura de precisão pois considera o rendimento das culturas quanto a variabilidade espacial.

2.1.1 Agricultura de Precisão (AP)

De acordo com Coelho (2005), desde meados da década de 1980, um grande número de termos tem sido usado para descrever o conceito da AP, são eles:

(i) Agricultura por metro quadrado (Reichenberg e Russnogle, 1989);

(ii) Agricultura com base em tipos de solos (Carr *et al*. 1991; Larson e Robert, 1991);

(iii) Aplicação de insumos a taxas variáveis – VRT (Sawyer, 1994);

(iv) Variável espacial, precisão, prescrição, ou manejo específico de culturas (Schueller, 1991); por fim,

(v) Manejo por zonas uniformes (Pierce e Sadler, 1997).

Ainda segundo Coelho (2005), o manejo de solos usando AP, tem por definição a propriedade de identificar e analisar características de solo, histórico de cultivo, clima e outras variáveis do sistema de produção, em diferentes locais dentro do campo. Muito embora sejam encontradas inúmeras definições para a agricultura de precisão, todas elas caminham em uma só direção que é a utilização de métodos de maneira pontual na área destinada ao plantio.

São, portanto, englobados na AP aspectos da variabilidade dos solos, clima, diversidade de culturas, performance de máquinas agrícolas e insumos (físicos, químicos e biológicos) naturais ou sintéticos, usados na produção das culturas. Com base nesses princípios, Pierce e Nowak (1999) utilizam a seguinte definição:

> *"Agricultura de Precisão é a aplicação de princípios e tecnologias para manejar a variabilidade espacial e temporal, associada com todos os aspectos da produção agrícola, com o objetivo de aumentar a produtividade na agricultura e a qualidade ambiental"*

Vale ressaltar que a AP, tem por princípio básico o manejo da variabilidade do solo e cultura no espaço e no tempo, como mencionado anteriormente. Com tudo, sem essa variabilidade, o conceito de agricultura de precisão tem pouco significado e de acordo com Mulla e Schepers (1997) nunca teria evoluído.

2.1.2 O mapa e sua importância na agricultura

Joly (1990) utiliza a seguinte definição quando se refere a um mapa.

> *"Um mapa é uma representação geométrica plana, simplificada e convencional, do todo ou de parte da superfície terrestre, numa relação de similitude conveniente denominada escala"*

Para ser eficiente, o mapa, deve ser de fácil leitura. A percepção deve ser a mais instantânea possível, de modo que em um tempo curto seja possível lê-lo e entendê-lo de acordo com os princípios da cartografia. Por meio deles, pode-se ter uma imagem geral sobre uma configuração geográfica e obter dados usados para informação e orientação de decisões (JOLY, 1990).

A leitura de mapas na agricultura, por meio do geoprocessamento, objetiva descrever como se configura uma determinada área, na intenção de conhecer aspectos relacionados à vegetação, clima, presença de rios e lagos, além das riquezas do solo que a área destinada para o plantio oferece, relacionando produtividade e lucratividade da cultura segundo a área que se dispõe, por exemplo.

No Brasil, o processo de abordagem agrícola georreferenciada, se dá inicialmente com o uso do mapeamento de um imóvel rural referenciando os vértices de seu perímetro ao Sistema Geodésico Brasileiro, definindo sua área e sua posição geográfica. Tudo para regularizar o registro dos imóveis rurais, obedecendo a legislação vigente (Lei 10.267/01 e Decretos 4.449/02 e 5.570/05)

Como exemplificação da utilização de mapas temáticos no processo agrícola, pode-se destacar o trabalho apresentado por Antunes *et al*. (2012), onde os autores evidenciam que a

estimativa da área plantada (para o estudo utilizou-se: área plantada de soja) é uma das principais informações empregadas na previsão de safras agrícolas.

Antunes *et al*. (2012) objetivaram, portanto, estimar a área plantada com soja por meio da normalização da matriz de erros (oriunda dos pixels) gerada a partir da classificação supervisionada de mapa temático em formato de imagens TM/Landsat-5[1]. No trabalho apresentado por Antunes *et al*. (2012), nas classificações digitais, as áreas são estimadas por contagem de *pixels* de toda a região em estudo, sem a necessidade de amostragem. Outras aplicações de análises por meio de mapas são de relevada importância no contexto agrícola.

2.2 Sistema de Informações Geográficas (SIG)

De acordo com Abreu (2012), historicamente, percebe-se a evolução técnica no domínio das ferramentas cartográficas (Sistemas de Coordenadas, de Projeção Cartográfica, Métodos de Posicionamento, Processos de Representação). Nesta evolução, destacam-se os Sistemas de Informações Geográficas (SIG).

Abreu (2012) esclarece, ainda, que seu surgimento é recente, por volta dos anos 60, com o CGIS (*Canada Geographical Information System*). Porém, ainda hoje, não há uma definição única para o SIG. Um dos conceitos que nos últimos anos frequentemente é citado nas literaturas é o proposto por Chrisman (2007), onde o autor define que os SIGs são "Sistemas de computadores e periféricos, programas, dados, pessoas, organizações e instituições com o propósito de coletar, armazenar, analisar e disseminar informações sobre áreas da Terra".

Uma definição mais modesta e igualmente referenciada é a de Aronoff (1999) citado por Abreu (2012) o qual define que SIG são sistemas computacionais usados para armazenar e manipular informações geográficas. Abreu (2012) destaca, também, que independentemente da definição, o SIG é a principal ferramenta de apoio a diagnóstico, planejamento e tomada de decisão quando a informação é passível de ser geoespacializada.

[1] A série Landsat (*Land Remote Sensing Satellite*), iniciou-se em 1972 com o lançamento do satélite ERTS-1. Ela teve sequência com os Landsat 2, 3, 4 e sobretudo com o Landsat 5 e 7. O principal objetivo do sistema Landsat foi o mapeamento multispectral em alta resolução da superfície da Terra. Esse é o sistema orbital mais utilizado na Embrapa Monitoramento por Satélite no mapeamento da dinâmica espaço-temporal do uso das terras e em todas as aplicações decorrentes.

Existe, para informações geoespacializadas segundo Soares Filho (2000), entes que compõem um modelo em Geoprocessamento e são considerados como discretos ou contínuos complexo. Uma outra definição dado aos que Soares Filho se refere como entes, são os de modelos de campo e de objeto. Em suma, os modelos de campo compreendem a fenômeno contínuo no espaço (teor de algum mineral no solo, temperatura, etc.), e o modelo de objeto representa uma coleção de dados distintos e identificáveis no campo (mapa raster, por exemplo).

Para exemplificar os entes citados por Soares Filho (2000), pode-se destacar como entes discretos indústrias, propriedades e vias urbanas, e como entes contínuos complexos o relevo, teor de minério no solo, temperatura entre outros. A representação dos entes discretos se dá por um dos três modos de implantação cartográfica, ou seja, o ponto, a linha ou a área.

Já os contínuos são representados por superfícies matemáticas, grades regulares ou irregulares e pelo formato *raster*[2]. Como vantagem da estrutura *raster*, Soares Filho (2000) cita que, neste formato, o espaço geográfico está uniformemente definido e sua estrutura se aproxima mais da arquitetura dos computadores, o que facilita avaliações matemáticas, lógicas de múltiplas camadas e maior capacidade analítica permitindo o uso de técnicas de processamento de imagem.

2.2.1 Imagem *Raster*

Segundo Levine (1993) um arquivo de imagem *raster* é um vetor de pontos, onde cada um destes pontos é chamado de *pixel*. Cada *pixel* é armazenado com um número que representa sua cor. Já Gonzalez (1992), define que um arquivo *raster* pode ser considerado como sendo uma matriz cujos índices de linhas e de colunas identificam um ponto (*pixel*) na imagem, e o correspondente valor do elemento da matriz identifica a cor naquele ponto. Os elementos dessa matriz digital são chamados de elementos da imagem, elementos da figura, célula, *pixel* ou *pels*, estes dois últimos, abreviações de *picture elements* (elementos de figura).

[2] Também chamado de representação matricial. É uma estrutura de dados celular composta de linhas e colunas para o armazenamento de imagens. Grupos de células como mesmo valor representam feições.

2.2.1.1 Características de um mapa *raster*

O conjunto de dados *raster* representam características geográficas, dividindo o "mundo" em pequenas células quadradas ou retangulares dispostos em um *grid*. Cada célula tem um valor atribuído a uma cor, este valor é utilizado para representar uma característica da localização, tal como a temperatura, a altitude, ou um valor espectral, por exemplo. A Figura 1 apresenta uma representação gráfica de um mapa rasterizado (ARCGIS, 2012).

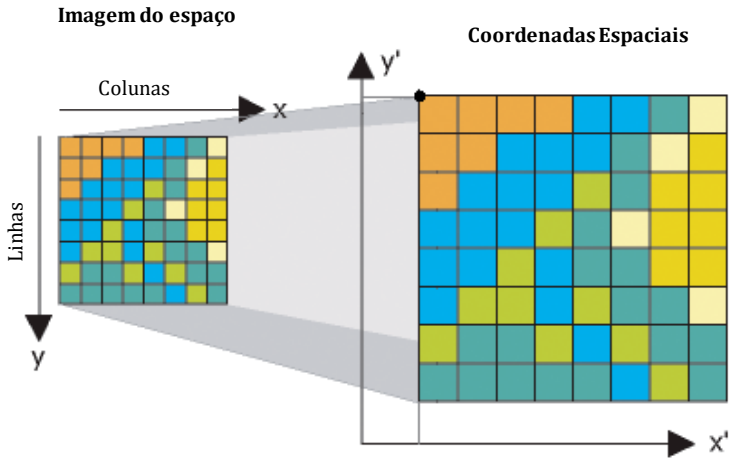

Figura 1: Representação gráfica de um mapa rasterizado. [Fonte: Adaptado de ARCGIS, 2012]

O conjunto *raster* é comumente usado para representar e gerenciar imagens, modelos digitais de elevação, e numerosos outros fenômenos. Frequentemente rasters são usados como uma forma de representar pontos, linhas, e as características de polígonos contidos num mapa. A Figura 2, apresenta um exemplo da aplicação de rasterização. Nela, pode-se perceber como uma série de polígonos seria representada como um conjunto de dados *raster*.

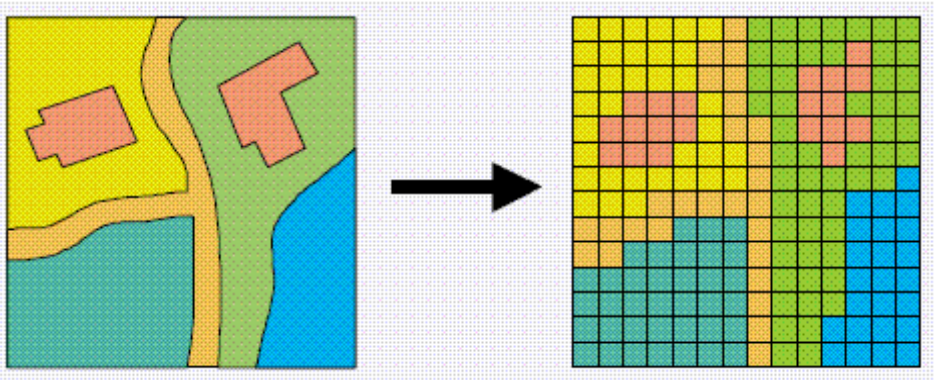

Figura 2: Representação gráfica da codificação de um mapa de polígonos para um mapa raster. [Fonte: Adaptado de ARCGIS, 2012]

Os *rasters* podem ser utilizados para representar toda a informação geográfica (características, imagens e superfícies) existentes em um mapa temático, e eles têm um rico conjunto de operadores em geoprocessamento. Além de ser um tipo de dado universal para a realização de imagens em SIG, o *raster* também pode ser utilizadas como um poderoso recurso, permitindo que todos os objetos geográficos sejam passiveis de serem modelados e analisados algebricamente.

Quatro propriedades geográficas são estendidas para os conjuntos de dados *raster*. Estes tornam-se úteis para georreferenciamento e contribui para explicar como os arquivos de dados *raster* são estruturados. Estes conceitos são importantes para entender como os rasters são armazenadas e gerenciadas em uma base de dados.

As propriedades geográficas para um *raster* incluem tipicamente:

- O seu sistema de coordenadas;
- Uma coordenada de referência ou localização *x*, *y*;
- Um tamanho de célula;

Esta informação pode ser usada para encontrar a localização de qualquer célula específica. Ao ter esta informação disponível, a estrutura de dados de quadriculação lista todos os valores das células, partindo da célula superior esquerda ao longo de cada linha até a parte inferior da célula para a direita, conforme apresentado na Figura 3.

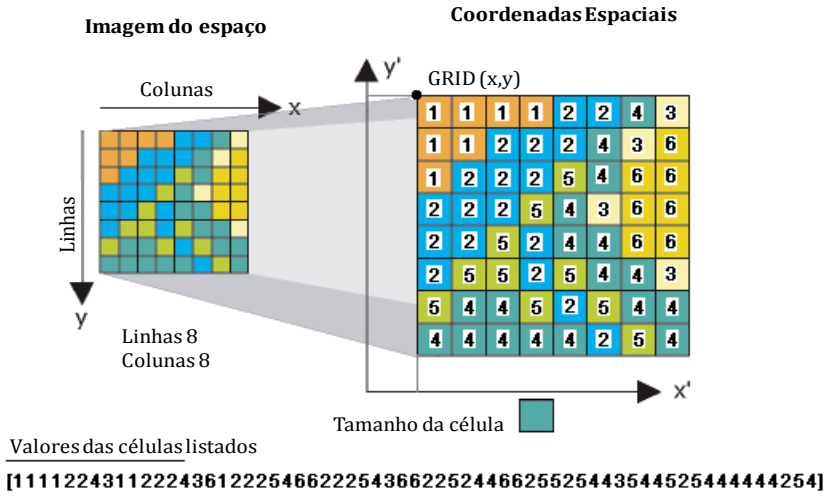

Figura 3: Representação gráfica de como se realiza a localização dos pixels no mapa *raster*. [Fonte: Adaptado de ARCGIS, 2012]

Vale ressaltar que o conjunto de dados *raster* têm uma maneira especial de definir a localização geográfica. Uma vez que as células ou pixels pode exatamente ser georreferenciada, é fácil ter uma lista ordenada de todos os valores das células em um *raster*. Isto significa que cada conjunto de dados de quadriculação tem um registro de cabeçalho que prende as suas propriedades geográficas, e o corpo do conteúdo é simplesmente uma lista ordenada dos valores das células.

2.3 Funções algébricas de mapas

As funções de mapas utilizadas no SIG podem ser dividas em consulta, reclassificação, análise de proximidade, contiguidade, modelos digitais de elevação, operações algébricas não cumulativas e operações algébricas cumulativas. A implementação dessas funções exige certos procedimentos metodológicos que determinam o controle da qualidade dos resultados (SILVA, 2003).

Os dados existentes sobre uma determinada área em forma digital, como imagens de satélites mapas geológicos, imagens geofísicas, mapas geoquímicos, geomorfológicos, fotografias e todo material que descreve o mundo real com um mínimo de interpretação, são considerados, individualmente, como *mapas observacionais*.

Silva (2003) afirma que todo conjunto de mapa observacional pode ser manipulado na sua forma digital produzindo produtos, tais como: imagem de falsa cor, modelos de elevação digital, mapas de declividade e aspecto, ou seja, permitem tratamento numérico via processamento digital de imagem e geram os chamados *mapas analíticos*.

Outras definições, decorrentes das funções aplicadas aos mapas, são as de *mapas integrados* e *mapas fundidos*, que envolvem uma gama de procedimentos tais como:

(i) Álgebra cumulativa: Corresponde a operações tipo adição, subtração, multiplicação e divisão entre as matrizes que correspondem aos arranjos dos dados espaciais contidos em mapas de georreferenciamento.

(ii) Álgebra não cumulativa: Permite cruzamento e integração de mapas por meio de modelos lógicos como simultaneidade *Booleana*, possibilidade *fuzzy* e probabilidade *Bayesiana*.

2.3.1 Álgebra de mapas

Cordeiro *et al*. (2007) relatam que o tema "álgebra de mapas" foi popularizado a partir dos livro "*Geographic Information System and Cartographic Modeling*" (Tomlin, 1990)[3]. Esta foi a primeira abordagem em que se buscou explorar de uma maneira formal as propriedades dos dados em SIG, usualmente representados por mapas.

Cordeiro *et al*. (2007) cita, ainda, que ferramentas como o GRID (ArcInfo), o IDRISI e o IDL, foram essencialmente concebidas sob tal paradigma, no qual operações de modelagem são representadas por sequências de operações primitivas descritas através de uma linguagem que procura respeitar as propriedades dos tipos de dados envolvidos.

Segundo Meneses *et al*. (2012), as operações aritméticas entre bandas é uma das mais simples formulações algorítmicas de processamento de imagens e que pode ter resultados expressivos. A facilidade para executar as operações aritméticas de soma, subtração, multiplicação e divisão é uma notável demonstração das vantagens do uso de processamento de imagens multiespectrais.

[3] Cordeiro *et al*. (2007) recomenda também Tomlin e Berry (1979); Tomlin (1983) e Berry (1987).

O processo algébrico é executado pixel a pixel por meio de uma regra matemática pré-definida envolvendo, normalmente, no mínimo duas bandas do mesmo sensor ou bandas de datas de aquisição diferentes que resulta em outro mapa com os resultados do processo algébrico utilizado (Figura 4).

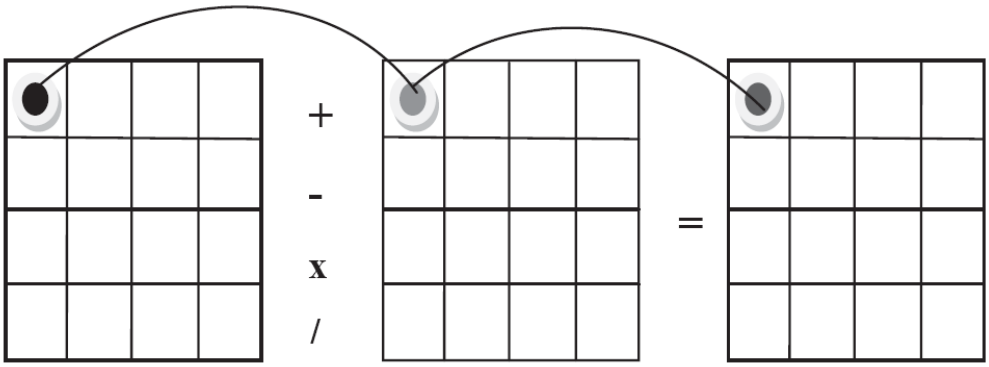

Figura 4: Representação das operações aritméticas pixel a pixel executadas em diferentes bandas. [Fonte: Adaptado de Meneses *et al*. 2012]

De acordo com Silva (2003), as principais operações matemáticas para modificar os dados não espaciais compreendem a operações lógicas, aritméticas, trigonométricas, estatísticas e multivariadas. A saber:

- ***Operações lógicas***: São baseadas na definição de hipóteses falsas (0) e verdadeiras (1) e podem resultar em união, intersecção, negação e exclusão.
- ***Operações aritméticas***: Correspondem aos resultados obtidos com adição, subtração, multiplicação, exponenciação, logarítmica (natural ou na base 10), truncamento e radiciação.
- ***Operações trigonométricas***: Podem relacionar seno, co-seno, tangente ou seus inversos.
- ***Operações estatísticas***: Compreendem média, moda, mediana, desvio padrão, variância, mínimo, máximo, entre outras.
- ***Operações Multivariadas***: Podem ser modelos de regressão, análise fatorial, componentes principais, análise de correspondência, probabilidade, entre outras.

No ANEXO II está contido um quadro que apresenta as operações comumente utilizadas no geoprocessamento.

2.4 Exatidão ou acurácia de mapas

De acordo com Vieira (2000), no processo de análise dos dados do sensoriamento remoto, por exemplo, um passo fundamental é a avaliação da precisão temática. Na intenção de saber quão confiáveis são os dados provenientes dos mapas temáticos, derivados da classificação ou interpolação de uma análise espacial. Uma forma de captar essa exatidão se dá por meio da matriz de confusão onde é possível derivar medidas e consequentemente verificar erros oriundos do processo de atribuição dos *pixels* a determinadas classes.

A avaliação do processo de alocação dos *pixels*, no contexto cartográfico, que se vale da chamada matriz de confusão ou matriz de erros é denominada de exatidão ou acurácia e usa medidas estatísticas de concordância. Onde, para o caso cartográfico ou de sensoriamento remoto, faz referência a concordância e omissão entre o número de *pixels* que foi classificado por um processo de interpolação, com o número de *pixels* da imagem usada como referência.

Congalton (1991) relata que o uso do coeficiente Kappa é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real).

Porém, Foody (1992) observou que o grau de concordância por chance poderia estar sendo superestimado, pelo fato de incluir também a concordância real, e por causa disso a magnitude de *Kappa* não refletiria a concordância presente na classificação, apenas descontada a casualidade, ou seja, leva em consideração duas vezes o total de acertos. Na tentativa de corrigir essa deficiência no cálculo do índice Kappa, Ma e Redmond (1995) propuseram um outro índice para a medição da precisão da classificação, o índice Tau.

Figueiredo e Vieira (2007) salientam que apesar de esses índices serem amplamente usados pela comunidade científica, não existem estudos que indiquem como esses índices se comportam, a respeito da variação do número de classes informadas ou do número de padrões

de validação. Dado que esses índices levam em consideração ou o número total de classes ou o número total de padrões de validação; ou mesmo se houver discrepância entre os valores amostrados, para validação, entre as classes estabelecidas.

No estudo realizado por Figueiredo e Vieira (2007), os autores concluíram que as diferenças entre os três índices (*Exatidão Global*, *Kappa* e *Tau*) não são constantes ao longo dos níveis de desempenho da classificação. No geral, a diferença entre os índices Kappa e Tau foi muito pequena. Os autores chegaram a conclusão que embora a Exatidão Global apresente um valor mais alto, os coeficientes de concordância Kappa e Tau são mais consistentes por envolver no valor final todas as células da matriz de confusão.

2.4.1 Matriz de confusão ou de erros

A acurácia é normalmente expressa em termos de índices que são calculados a partir de matrizes de erros que expressam a concordância entre a imagem classificada e o conjunto de amostras de referência. A matriz de erros compara, classe por classe, a relação entre os dados de verdade terrestre (dados de referência) e os correspondentes resultados da classificação. O número de linhas e o número de colunas dessa matriz devem ser iguais ao número de classes espectrais do estudo. Erros de omissão (exclusão) e de comissão (inclusão) de cada classe são calculados a partir dessa matriz.

Segundo Antunes *et al*. (2007), corroborado por Jupp (1989); Congalton e Green (1999), De Wit e Clevers (2004); Serra e Pons (2008), Peña-Barragán *et al*. (2011), a matriz de erros ou confusão, bem como as métricas de exatidão global e o índice *Kappa*, vem sendo utilizada para determinar a acurácia de classificações digitais mediante a utilização de imagens de satélites.

Essa matriz permite avaliar o desempenho da classificação realizada para uma classe individual, particularmente quando um pequeno número de classes de uso do solo é de interesse, como, por exemplo, na estimativa de área de uma cultura agrícola (ANTUNES *et al*. 2012 *apud* CEBALLOS-SILVA e LÓPEZ-BLANCO, 2003).

A matriz de confusão é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma categoria particular

relativa, inferida por um classificador (ou regra de decisão), comparado com a categoria atual verificada no campo (CONGALTON, 1991).

De acordo com Figueiredo e Vieira (2007), normalmente abaixo das colunas representa-se o conjunto de dados de referência que é comparado com os dados do produto da classificação que são representados ao longo das linhas. Os elementos da diagonal principal indicam o nível de acerto, ou concordância, entre os dois conjuntos de dados. A Tabela 1 apresenta a representação de uma matriz de confusão.

Tabela 1: Representação matemática de uma matriz de confusão.

Classificação	Dados de Referência				$\sum n_{i+}$
	1	2	…	p	
1	x_{11}	x_{12}	…	x_{1p}	x_{1+}
2	x_{21}	x_{22}	…	x_{2p}	x_{2+}
⋮	⋮	⋮	⋱	⋮	⋮
p	x_{p1}	x_{p2}	…	x_{pp}	x_{p+}
$\sum n_{+i}$	x_{+1}	x_{+2}	…	x_{+p}	N

As medidas derivadas da matriz de confusão são: a exatidão global, precisão de classe individual, precisão de produtor, precisão de usuário, índice *Kappa*, entre outros. Um resultado com 100% de acurácia significa que todos os pixels da imagem foram classificados de forma correta, segundo um conjunto de dados que compõe a verdade terrestre. Um resultado com 50% de acurácia significa que, em teoria, metade dos pixels da imagem foi classificada corretamente essa classificações são apresentadas pela matriz de confusão.

Meneses e Almeida (2012) alertam que a acurácia depende de uma série de fatores como a complexidade do terreno, as resoluções espaciais e espectrais do sistema sensor, o próprio algoritmo de classificação utilizado, a legenda utilizada no processo de classificação e o conjunto de dados que representa a verdade terrestre.

2.4.2 Índice Kappa

Desde a introdução da estatística kappa, por Cohen (1960), estudos e pesquisas têm sido realizados para medir a concordância entre avaliadores corrigida pelo acaso. Cohen, originalmente, formulou kappa para uso onde dois observadores designam cada indivíduo a uma das categorias de uma escala nominal. Nessa abordagem as discordâncias observadas entre as avaliações possuem pesos iguais.

Modificações desse coeficiente foram propostas para uso em outras situações. Cohen (1968) mostrou como a concordância pode ser medida quando se atribui uma ponderação à discordância. Esse índice kappa ponderado foi estudado por inúmeros autores [Cicchetti (1981); Cicchetti e Fleiss (1977) e Fleiss, Cohen e Everitt (1969)].

Recentemente, têm sido desenvolvidas diferentes abordagens que utilizam de modelagem estatística para medir a concordância entre dois avaliadores, como é o caso do geoprocessamento. A modelagem estatística facilita e enriquece a análise, pois, especifica o tipo e a quantidade de concordância presente nos mapas.

O índice kappa simples, introduzida por Cohen (1960), é uma medida de concordância dada por

$$\hat{\kappa} = \frac{\theta_1 - \theta_2}{1 - \theta_2}$$

onde $\theta_1 = \frac{\sum_{i=1}^{p} x_{ii}}{n}$ e $\theta_2 = \frac{\sum_{i=1}^{p} x_{i+} x_{+i}}{n^2}$ são obtidos na matriz de confusão, apresentada na Tabela 1 da seção 2.4.1.

O índice kappa permite a obtenção de uma medida que caberá ao pesquisador avaliar se essa medida é satisfatória ou não, isto baseado, por exemplo, em dados de literatura ou pesquisas anteriores. Fonseca (2000) sugere a interpretação apresentada na Tabela2 para as medidas obtidas no cálculo do índice.

Tabela 2: Índice Kappa e o correspondente desempenho da classificação.

Índice	Desempenho
< 0,0	Péssimo
0,0 < $\kappa \leq$ 0,2	Ruim
0,2 < $\kappa \leq$ 0,4	Razoável
0,4 < $\kappa \leq$ 0,6	Bom
0,6 < $\kappa \leq$ 0,8	Muito bom
0,8 < $\kappa \leq$ 1,0	Excelente

Fonte: Adaptado de Fonseca (2000).

Contudo, de acordo com Batista (2012), o valor do Índice Kappa por si só, não tem a capacidade de dizer se existe uma concordância ou não entre dois mapas. É preciso avaliar a significância estatística do valor obtido para o mesmo. Para tanto, é razoável, realizar um teste estatístico para a significância do índice Kappa.

Neste caso a hipótese testada é avaliada pelo teste *Z* e se por ventura o valor da estatística de teste for igual a 0 (zero), indicará concordância nula, ou se for maior do que zero, indicará concordância maior do que o acaso (teste monocaudal: $H_0 : \kappa = 0$; $H_1 : \kappa > 0$). Pode-se encontrar em literaturas especializadas [Thompson (2001); Conover (1999); Agresti (1990); Siegel e Castellan (1988); Landis e Koch (1977)] um contexto explicativo indicando que a obtenção de um valor negativo para a estatística de teste utilizada para avaliar a significância do índice Kappa, não tem interpretação cabível e pode resultar num paradoxal nível crítico (valor de *p*) maior do que um.

A estatística do teste *Z* utilizada de acordo com Congalton e Green (2009) é dada por

$$Z = \frac{\hat{\kappa} - \kappa}{\sqrt{Var(\hat{\kappa})}} \sim N(0,1).$$

A obtenção de variâncias, segundo Agresti (2002), é fundamentada no método delta. A variação, por este método, é obtida a partir da expressão

$$Var(\hat{\kappa}) = \frac{1}{n}\left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4}\right]$$

onde

$$\theta_3 = \frac{\sum_{i=1}^{p} x_{ii}(x_{i+} + x_{+i})}{n^2} \quad \text{e} \quad \theta_4 = \frac{\sum_{i=1}^{p}\sum_{j=1}^{p} x_{ij}(x_{j+} + x_{+i})}{n^3}.$$

2.5 Geoestatística

A geoestatística se vale da teoria das variáveis regionalizadas[4]. Nesta teoria, segundo Matheron (1963) citado por Silva *et al*. (2011), a diferença nos valores de uma dada variável tomados em dois pontos no campo depende da distância entre eles. Andriotti (2003) cita que um ponto importante a ser destacado nessa teoria é a relevância dada as relações espaciais existentes entre as observações que compõe uma amostra.

Estas relações espaciais são captadas por meio do semivariograma. A geoestatística estuda essa estrutura entre os dados, modelando as influências do ponto de vista geográfico. A medida que a distância aumenta as relações espaciais entre os dados fica cada vez mais fraca, podendo então ser analisadas por métodos estatísticos clássicos. A Figura 5 apresenta graficamente o exposto.

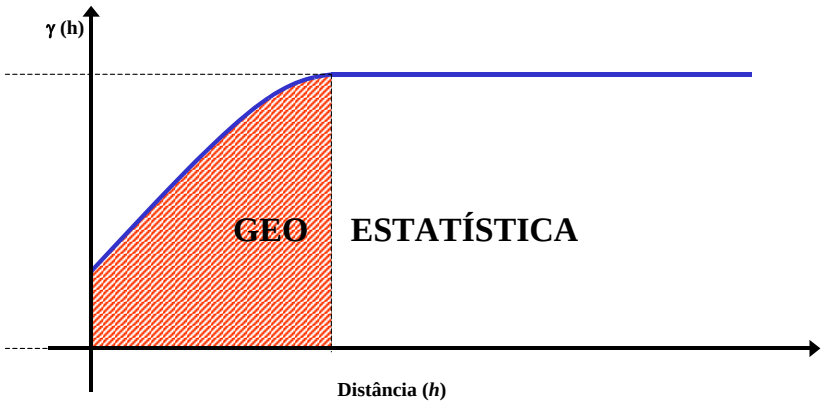

Figura 5: Representação gráfica de um caso hipotético onde atua a geoestatística e a estatística clássica.

É importante destacar que os ramos da estatística, tato a estatística dita Clássica como a Geoestatística, ambos abordam variáveis aleatórias. No entanto, para a Estatística Clássica uma variável é considerada aleatória quando o valor da mesma é independente e identicamente distribuído obtido através de observações ou experimentos (CASELLA e

[4] Para uma abordagem mais detalhada a respeito da Teoria das variáveis regionalizadas recomenda-se consultar Santos (2010); Andriotti (2003) e Yamamoto (2001).

BERGER, 2010; MOOD, GRAYBILL e BOES, 1974), e cada valor está associada a uma certa probabilidade se valendo da Teoria das Probabilidades.

Ao passo que a Geoestatística está baseada na Teoria das Variáveis Regionalizadas (SANTOS, 2010), que considera aspectos aleatórios e estruturados do fenômeno em estudo. Andriotti (2003) cita que o fenômeno é aleatório no sentido de que os valores das medições feitas podem variar consideravelmente entre si e estruturado segundo uma certa lei no espaço considerando que os valores das observações não são independentes da sua localização geográfica, por tanto, dependentes espacialmente como indica a parte hachurada da Figura 5 e sem a possibilidade de realizar nova amostragem o mesmo ponto.

De acordo com Andriotti (2003), na década de 1970, a Geoestatística experimentou grandes avanços na conceituação teórica e nos campos de atividade em que se mostrou útil, tendo ocorrido naquele ano um notável crescimento da utilização dessa técnica no mundo todo. Isso ocorreu dado os avanços computacionais.

Santos (2010), a propósito, cita em seu trabalho que durante um longo período o principal obstáculo encontrado pela Geoestatística era a pequena capacidade de processamento dos computadores dado os cálculos envolvidos na aplicação dessa metodologia. O que explica os avanços que Andriotti (2003) referiu-se.

Atualmente ela tem aplicação rotineira em pesquisas nas mais diversas áreas de atuação. No contexto agrícola Vieira (2000), evidencia que sua utilização na agricultura de precisão apresenta aplicabilidade na pesquisa da variabilidade espacial dos atributos do solo e das plantas, bem como obter estimativas utilizando o princípio da variabilidade espacial e na identificação inter-relações destes atributos no espaço, além de permitir estudar padrões de amostragem adequadas.

2.5.1 Semivariograma

Huijbregts (1975), citado por Yamamoto (2001), define que o semivariograma é a ferramenta básica que permite descrever quantitativamente a variação no espaço de um fenômeno regionalizado. A natureza estrutural do conjunto de dados (assumido pela variável

regionalizada) é definida a partir da comparação de valores tomados simultaneamente em dois pontos, segundo uma determinada direção procedimento exercido pelo semivariograma.

Santos (2010), explica que o nível de dependência espacial entre duas variáveis regionalizadas é representado por

$$2\gamma(h) = E\ [Y(x) - Y(x+h)]^2\ = \mathrm{var}[Y(x) - Y(x+h)].$$

Segundo Vieira (2000), dentre todos os estimadores de semivariâncias o mais utilizado é o baseado no método de momentos proposto por Matheron (1963), e dado por

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

onde $\hat{\gamma}(h)$ é o estimador da semivariância na distância h, $N(h)$ é o número de pares de valores médios, $Y(x_i)$ e $Y(x_i + h)$ separados por um vetor distância.

2.5.1.1 Caracterização dos parâmetros do semivariograma

Por meio do semivariograma deve-se obter os parâmetros da estrutura de dependência espacial, úteis no processo de predição geoestatística (SANTOS, 2010). A Figura 6 apresenta graficamente os seguintes parâmetros:

- ***Alcance*** (*a*): É a distância dentro da qual os valores amostrais apresentam-se correlacionadas espacialmente. É o raio de dependência espacial.
- ***Patamar*** (*C*): é o valor do semivariograma correspondente ao valor do alcance (a), ou seja, é o valor constante atingido por $\hat{\gamma}(h)$ quando a distância entre os dados, *h*, cresce. Deste ponto em diante, considera-se que não existe mais dependência espacial entre as amostras.
- ***Efeito Pepita*** (C_0): é o valor da semivariância para a distância zero, representa a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras. Parte desta descontinuidade pode ser também devida a erros de

medição, mas é impossível quantificar se a maior contribuição provém dos erros de medição ou da variabilidade de pequena escala, não captada pela amostragem.

- ***Contribuição*** (C_1): é a diferença entre os valores do patamar (C) e do Efeito Pepita (C_0).

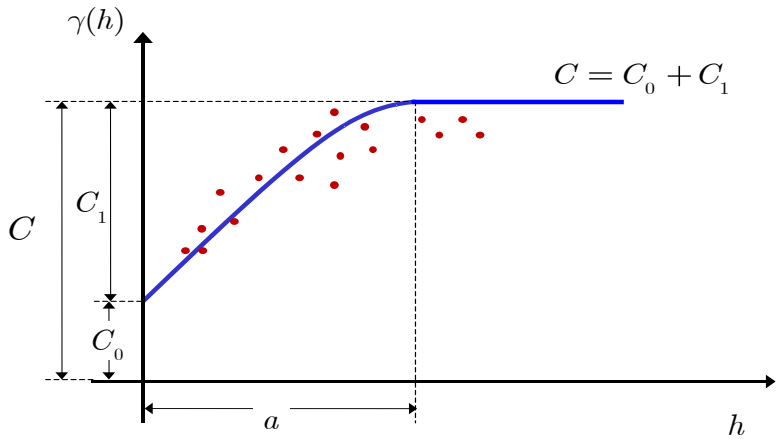

Figura 6: Representação gráfica de um semivariograma e seus parâmetros Alcance (a), Efeito Pepita (C_0), Contribuição (C_1) e Patamar ($C = C_0 + C_1$).

O chamado semivariograma experimental é construído, de acordo com Andriotti (2003), segundo uma linha, um plano ou em três dimensões. Para sua construção, são *plotados* sobre o eixo das ordenadas os valores estimados das semivariancias [$\hat{\gamma}(h)$] e sobre o eixo das abscissas o espaçamento para cada distância (h) entre as observações de campo.

2.5.2 Modelos teóricos de Semivariograma

Para a análise geoestatística é necessário utilizar um modelo que "melhor" se ajuste aos dados, geralmente os modelos são predefinidos e classificados de acordo à característica de atingir ou não o patamar ($C = C_0 + C_1$). Os modelos usuais são: Esférico, Exponencial e Gaussiano.

(i). O *modelo esférico* apresenta crescimento rápido na origem, onde tem um comportamento linear e caracteriza-se por atingir completamente o patamar e sua função é definida por

$$\gamma(h) = \begin{cases} 0 & , \quad h = 0 \\ C_0 + C_1\left[\frac{3}{2}\left(\frac{h}{a}\right) - \frac{1}{2}\left(\frac{h}{a}\right)^3\right], & 0 < h < a \\ C_0 + C_1 & , \quad h \geq a \end{cases}$$

(ii). O *modelo exponencial* também apresenta comportamento linear à origem, e sua expressão é

$$\gamma(h) = \begin{cases} 0 & , \quad h = 0 \\ C_0 + C_1\left[1 - e^{\left[-3\left(\frac{h}{a}\right)\right]}\right], & h \neq 0 \end{cases}$$

onde $d = h$ representa a distância máxima. O alcance, nesse modelo, tem significado puramente analítico, sendo o patamar só alcançado assintoticamente quando $h \to \infty$.

(iii). O *modelo de Gauss* ou *parabólico* é o modelo que reflete mais regularidade da variável estudada, tendo tangente horizontal na origem, presença de efeito pepita (C_0), e sua expressão é dada por

$$\gamma(h) = \begin{cases} 0 & , \quad h = 0 \\ C_0 + C_1\left[1 - e^{\left[-3\left(\frac{h}{a}\right)^2\right]}\right], & h \neq 0 \end{cases}.$$

Os modelos exponencial e gaussiano, diferente do modelo esférico, só atingem o patamar assintóticamente ($h \to \infty$) com o parâmetro *a* definido como o alcance prático ou a distância na qual o valor para ambos modelos é 95% do patamar (ISAAKS e SRIVASTAVA, 1989). A Figura 7 apresenta graficamente este conceito.

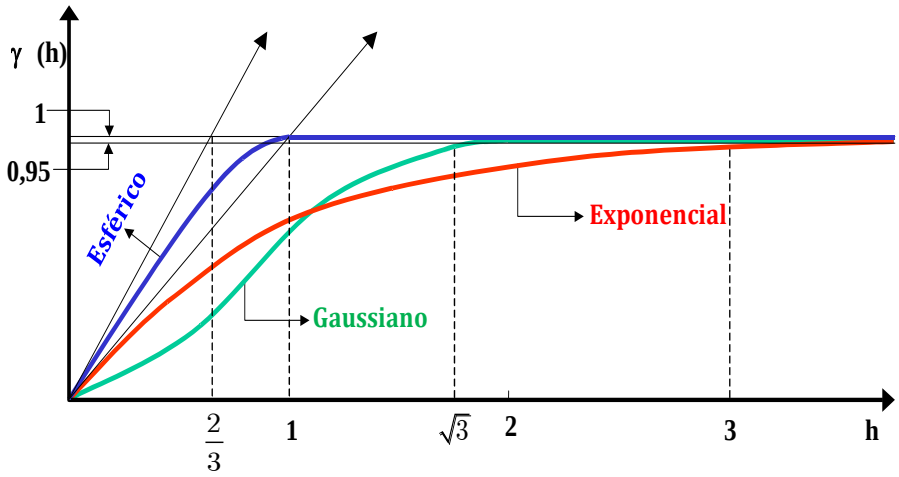

Figura 7: Representação dos modelos de semivariogramas usualmente utilizados (Esférico, Guassiano e Exponencial).

Vale salientar que os cálculos de Geoestatística dependem do valor do modelo do semivariograma para cada distância (*h*) especificada (VIEIRA *et al*., 1981). Sendo assim, é importante que o modelo ajustado represente a tendência do semivariograma em relação à distância. Desse modo, as estimativas da krigagem serão mais exatas e, portanto, mais confiáveis (CAMARGO, 1997).

2.5.3 Índice de dependência espacial

Conforme critérios estabelecidos por Zimback (2001) o índice de dependência espacial (IDE) é dado por

$$IDE = \frac{C}{C_0 + C} \times 100$$

e a classificação quanto ao grau de dependência espacial da variável em estudo assume os seguintes intervalos: fraco para valores de IDE < 25%; moderado entre 25% ≤ IDE ≤ 75% e forte para IDE >75%.

Pode-se destacar que a determinação do IDE está diretamente ligada ao modelo teórico de semivariância e seus parâmetros, sendo importante a avaliação do IDE a partir do modelo

teórico ajustado, pois a escolha do modelo deve ser coerente com o que se espera na prática para o índice esperado do fenômeno em estudo.

Supondo que o modelo escolhido apresente um IDE conforme o esperado, a fase seguinte consiste em predizer os valores para os pontos que não foram amostrados. Isto pode ser realizado pela krigagem.

2.5.4 Krigagem

Conhecido o semivariograma da variável, e havendo dependência espacial entre as amostras, podem-se interpolar valores em qualquer posição no campo de estudo, sem tendência e com variância mínima (VIEIRA, 2000; SILVA *et al*., 2011).

O método de interpolação, na Geoestatística, chama-se krigagem e tem como base os dados amostrais da variável regionalizada e as propriedades estruturais do semivariograma obtido a partir destes dados o que permite visualizar o comportamento da variável na região através de um mapa temático (SILVA *et al*., 2011).

Existem diferentes tipos de Krigagem. Segundo Silva (2003), inicialmente esse método estatístico de interpolação pode dar uma impressão de complexidade, porém, o autor explica que os diferentes tipos de krigagem são técnicas de regressão que diferem apenas dos tipos peculiares de funções obtidas a partir dos dados que estão sendo combinados para obtenção da estimativa.

Para o presente trabalho será utilizado o método de Krigagem Ordinária que utiliza um estimador linear não-viciado com mínima variância, ou seja, estimador do tipo *Best Linear Unbiased Estimator* (BLUE), para interpolação do atributo medido em posições não amostradas (ANDRIOTTI, 2003; ISAAKS e SRIVASTAVA, 1989). O valor interpolado de uma variável regionalizada $Z(x_0)$, num local x_0, pode ser determinado por

$$\hat{Z}(x_0) = \sum_{i=1}^{n} \lambda_i Z(x_i)$$

onde $\hat{Z}(x_0)$ representa o valor estimado para o local x_0 não amostrado, $Z(x_i)$ são os valores obtidos por amostragem no campo e λ_i são os pesos associados ao valor médio na posição x_i.

De acordo com Silva *et al*. (2011) a "melhor" estimativa de $\hat{Z}(x_0)$ é obtida quando

1) O estimador é não tendencioso, ou seja, $E\left[\hat{Z}(x_0) - Z(x_0)\right] = 0$;
2) A variância da estimativa é mínima, logo, $Var[\hat{Z}(x_0) - Z(x_0)] = \textit{mínimo}$.

Segundo Silva *et al*. (2011), para que $\hat{Z}$ seja uma estimativa não tendenciosa de Z, a soma dos pesos das amostras deve ser igual a 1 $(\sum \lambda_i = 1)$. Para obter a variância mínima sob a condição o sistema de Krigagem resultante é dado por

$$\sum_{i=1}^{n} \lambda_i \gamma(x_i, x_j) + \mu = \gamma(x_i, x_0)$$

onde μ é o multiplicador de Lagrange. O sistema de equações da Krigagem contém $n+1$ equações e $n+1$ incógnitas e uma única solução produz *n* pesos λ e um multiplicador de Lagrange μ.

De acordo com Silva *et al*. (2011), em notação matricial chamando de $\boldsymbol{A}$ a matriz de variâncias dos valores amostrados envolvidos na estimativa de $\hat{Z}(x_0)$, λ a matriz coluna que contém os pesos λ_i e o multiplicador de Lagrange e $\boldsymbol{b}$ a matriz coluna das variâncias entre os valores amostrados e o ponto a ser estimado, tem-se

$$\boldsymbol{A}\lambda = \boldsymbol{b}$$

logo

$$\lambda = \boldsymbol{A}^{-1}\boldsymbol{b}$$

e a variância da estimativa σ_E^2 é dada por

$$\sigma_E^2 = \boldsymbol{b}^t \lambda.$$

As matrizes $\boldsymbol{A}$, $\boldsymbol{b}$ e λ são dadas por

$$\boldsymbol{A} = \begin{vmatrix} \gamma(x_1,x_1) & \gamma(x_1,x_2) & \dots & \gamma(x_1,x_n) & 1 \\ \gamma(x_2,x_1) & \gamma(x_2,x_2) & \dots & \gamma(x_2,x_n) & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \gamma(x_n,x_1) & \gamma(x_n,x_2) & \dots & \gamma(x_n,x_n) & 1 \\ 1 & 1 & \cdots & 1 & 0 \end{vmatrix} \quad \boldsymbol{b} = \begin{vmatrix} \gamma(x_1,x_n) \\ \gamma(x_2,x_n) \\ \vdots \\ \gamma(x_n,x_n) \\ 1 \end{vmatrix} \quad \lambda = \begin{vmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \mu \end{vmatrix}$$

Silva *et al*. (2011) ressalta que (1) a matriz $\boldsymbol{A}$ é simétrica e possui diagonal principal igual a zero, ou igual ao valor do efeito pepita, (2) os valores 1 que aparecem na matriz $\boldsymbol{A}$ e $\boldsymbol{b}$ são consequência do multiplicador de Lagrange e (3) o sistema deve ser resolvido para cada estimativa $\hat{Z}$ e para cada variação do número de amostras envolvidas na estimação.

2.5.5 Validação cruzada

De acordo com Andriotti (2003) validação cruzada é o procedimento mediante o qual cada amostra é retirada do conjunto de dados e é feita uma krigagem para avaliar seu valor, o valor médio das diferenças será tão mais próximo de zero quanto melhor for a estimativa. De modo resumido a validação cruzada processa-se da seguinte maneira:

a) É extraído do conjunto de dados original o valor correspondente a um determinado ponto amostrado (Z_i);
b) Utilizados os dados remanescentes do conjunto de dados, estima-se o valor desse ponto cujo o valor foi retirado do conjunto obtendo-se o valor $\hat{Z}_i$;
c) Obtém-se o erro cometido nessa estimação $(\hat{Z}_i - Z_i)$ e compara-se esse valor com $(Z_i - \hat{Z}_i)/\sigma_i$;
d) Repete-se os procedimentos descritos nos itens a, b e c para todas as observações disponíveis no conjunto de dados e procura-se observar se são verificadas as duas propriedades para o conjunto final obtido, tal que o valor médio dos valores $(\hat{Z}_i - Z_i)$

seja aproximadamente zero e a de que o valor médio de $[(\hat{Z}_i - Z_i)/\sigma_i]^2$ seja aproximadamente igual à unidade.

Deve haver também, ainda segundo Andriotti (2003), uma correlação entre os valores krigados e os valores originais do conjunto de dados, correlação esta representada por um de coeficiente de correlação linear em torno de 1.

2.6 Relações bidimensionais

Frequentemente, nos mais distintos ramos do conhecimento, há o interesse em analisar o comportamento conjunto entre duas ou mais variáveis aleatórias. Segundo Bussab (2005), os dados referentes às variáveis de interesse são dispostos em forma matricial, usualmente para o caso onde os dados são independentes e identicamente distribuídos (*iid*), as colunas desta matriz indicam as variáveis de interesse e as linhas, os indivíduos ou elementos. No contexto espacial os dados são igualmente representados de forma matricial, porém, os valores contidos nas linhas e colunas fazem referencia a posição a qual o mesmo se encontra.

Em análises estatísticas o primeiro passo é a identificação do tipo de variável a ser utilizada. Se a natureza da variável é métrica ou não métrica, o mesmo ocorre ao dado que foi observado, vale lembrar que mesmo em situações onde a observação é métrica ela pode ser passível de categorização e isso ocorre tanto em análises com abordagem da estatística clássica quanto da estatística espacial. Um exemplo de dados métricos porém que são categorizados na agricultura de precisão é a definição de zonas de manejo como indica Borem (2000) citado por Batista (2012).

Outro exemplo de categorização que ocorre em análises espaciais é realizado no cálculo do índice de exatidão Kappa apresentado na subseção 2.4.2, onde são estabelecidas classes iguais para os dois mapas em seguida os mesmos são comparados e como resultado o índice indica se há concordância entre os mapas. O referido índice realiza, então, uma associação entre os mapas avaliando suas concordâncias ou discordâncias.

As variáveis métricas bidimensionais são passíveis de procedimentos analíticos e gráficos mais refinados se comparados com as não métricas ou categorizadas. Bussab (2005), relata

que um dispositivo bastante útil para verificar associação entre duas variáveis métricas ou entre dos conjuntos de dados, é o *diagrama de dispersão*. Contudo se faz importante quantificar esse tipo de relação. Existe um vasto tipo de associação, para este trabalho será utilizada a relação mais simples que é a linear.

Uma ferramenta que quantifica a relação linear entre variáveis métricas é o coeficiente de correlação linear de Pearson (*r*). Esse coeficiente mede o grau de relação entre conjuntos de dados, Ramos *et al*. (2013) salienta que em termos quantitativos o seu valor varia na faixa de $-1 \leq r \leq +1$. Uma formulação simples do coeficiente pode ser representada por

$$r = \frac{\sum_{i=1}^{n}(x_i - \overline{x})(y_i - \overline{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \overline{x})^2 \sum_{i=1}^{n}(y_i - \overline{y})^2}},$$

onde $\overline{x} = \frac{1}{n}\sum_{i=1}^{n} x_i$, $\overline{y} = \frac{1}{n}\sum_{i=1}^{n} y_i$ e *n* é o tamanho amostral. Ramos *et al*. (2013), indica uma escala de referência para o grau de associação entre o conjunto de duas variáveis de interesse como apresentado na Figura 8.

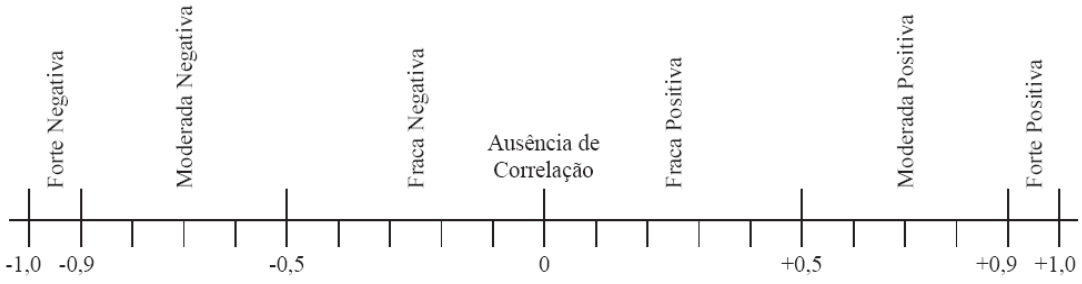

Figura 8: Escala de correlação linear entre variáveis. [Fonte: Adaptado de Ramos *et al.* 2013]

Como apresentado na Figura 8, pode-se observar que para $r = +1$ os pontos desenhados no diagrama de dispersão estão perfeitamente alinhados em uma reta que passa por eles com inclinação positiva. O valor de $r = 0$ indica que não existe grau de relação linear entre as variáveis analisadas e $r = -1$ indica que a relação entre as variáveis é negativa.

O presente estudo parte da premissa que haja uma relação linear entre os mapas iguais. Daí a utilização do coeficiente de correlação de Pearson para os valores interpolados em um mapa temático condensados em pixels como descrito na seção 2.2.1.

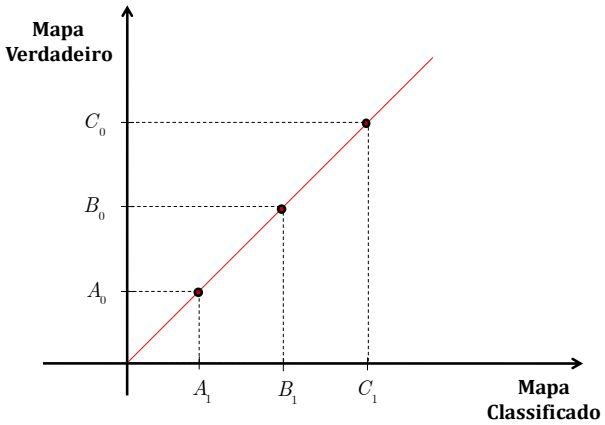

Figura 9: Esquema esperado para relação de concordância entre mapas.

A Figura 9 apresenta de forma gráfica a relação de concordância entre os mapas. O critério de concordância é o mesmo utilizado em análises que se valem deste coeficiente, ou seja, para valores iguais a zero conclui-se que não há concordância ou similaridade entre os mapas avaliados. Para valores próximos de 1 significa que há similaridade entre os mapas.

3. MATERIAL E MÉTODOS

Neste capítulo são apresentados os recursos e metodologia utilizada neste estudo. Descreve-se a forma de obtenção dos dados por meio de simulações, os softwares e as estatísticas utilizadas para a obtenção dos objetivos propostos.

3.1 Simulações

Para a realização do estudo foram simulados 27 cenários espaciais distintos combinando três tamanhos de grids (todos regulares), três graus de dependência espacial e três diferentes modelos de semivariograma. Com o objetivo de obter um conjunto de valores que pudesse representar cada cenário, foram gerados inicialmente 300 conjuntos de valores distintos para os pontos que compõem os grids em estudo (ANEXO I), o procedimento utilizado foi o SIM2D contido no programa SAS (SAS Institute Inc, 1999), onde os tamanhos de grids regulares simulados foram de 50×50, 100×100 e 150×150. Os modelos de semivariograma utilizados foram o gaussiano, esférico e o modelo exponencial.

Quanto aos níveis de dependência espacial incorporados nas simulações, seguiu-se a definição do Índice de Dependência Espacial (IDE) proposta por Zimback (2001), onde foram utilizados valores de 25% para fraca, 66,70% para moderada e 99,99% para forte. Portanto, para cada nível de dependência espacial adotado, foram simulados 9 cenários diferentes (Totalizando os 27 cenários).

Para a simulação desses diferentes cenários, previamente, foi necessária a determinação dos parâmetros: alcance (a), efeito pepita (C_0) e contribuição (C_1), de modo que os valores simulados se comportassem de maneira a representar cada cenário adotado. O que diferenciou-se entre eles foi o número de pontos observados, 121 pontos para o primeiro, 441 para o segundo e 961 para o terceiro cenário (grids de 50×50, 100×100 e 150×150, respectivamente).

Para determinar o nível de dependência espacial, o valor da contribuição foi mantido para todos os níveis sendo alterado somente o valor do efeito pepita (C_0) em cada um dos

índices de dependência espacial diferentes. O valor do alcance (*a*) de cada cenário foi escolhido de acordo com o proposto por Silva (2006). Ou seja, o alcance do modelo esférico representa um terço, e o do gaussiano, $1/\sqrt{3}$ do alcance teórico do modelo exponencial.

A escolha dos dados simulados entre as iterações realizadas se deu por meio da análise semivariográfica obtida a partir do comando PROC VARIOGRAM (SAS Institute Inc, 1999), onde escolheu-se as iterações que apresentaram parâmetros semivariográficos (alcance e patamar) iguais ou próximos aos definidos na realização da simulação (Tabela 3). Os códigos de programação utilizados nas simulações podem ser encontrados no ANEXO I e os valores dos dados simulados são referentes a uma variável cuja unidade de medida é expressa em *ppm* (parte por milhão).

Para captar a diferença entre os mapas temáticos distintos é necessário que seja estabelecido um como mapa de referência. Deste modo, nas simulações com estrutura de DE forte utilizou-se como referência o modelo gaussiano (*Gau*), para estrutura de DE moderada utilizou-se o modelo esférico (*Sph*) e o modelo exponencial (*Exp*) para as simulações com fraca DE, como pode ser observado na Tabela 3.

Tabela 3: Descrição da malha amostral (*Grid*), dos parâmetros e modelos utilizados nas simulações de dados.

Grid	*EDE*	C_0	C_1	*A*	Média	%*IDE*	Modelo
121	Fraca	3	4	15	0	0,250	*Exp*
	Moderada	1,5	4,5	15	0	0,667	*Sph*
	Forte	1×10^{-08}	3	15	0	0,999	*Gauss*
441	Fraca	3	4	40	0	0,250	*Exp*
	Moderada	1,5	4,5	40	0	0,667	*Sph*
	Forte	1×10^{-08}	3	40	0	0,999	*Gauss*
961	Fraca	3	4	40	0	0,250	*Exp*
	Moderada	1,5	4,5	40	0	0,714	*Sph*
	Forte	1×10^{-08}	3	40	0	0,833	*Gauss*

Nota: Estrutura de Dependência Espacial (EDE); Efeito Pepita (C_0); Contribuição (C_1); Alcance (*a*); Índice de Dependência Espacial (IDE).

Desta maneira, ao final, foram utilizados 2.700 conjuntos de valores distintos segundo os diferentes grid utilizados, sendo selecionado em cada um dos 27 cenários simulados o conjunto de dados que proporcionou melhor ajuste do modelo teórico utilizado na sua obtenção via simulação.

O conjunto de dados de cada cenário foi utilizado para gerar as predições por Krigagem Ordinária. Para cada cenário foi gerado uma predição usando o modelo de semivariograma teórico de referência e duas outras utilizando modelo de dependência espacial distinto. Foram feitas no total 81 krigagens (3 krigagens para cada um dos 27 cenários diferentes).

Um estudo de validação cruzada foi realizado para cada uma destas predições. A partir da validação cruzada foram obtidas estatísticas dos erros de predição. As estatísticas utilizadas foram a média dos erros de predição (ME) e a raiz quadrada do erro quadrático médio do erro de predição padronizado (RMSS) que podem ser averiguadas nas Tabelas 8, 9 e 10 da seção Validação. A comparação do valor destas estatísticas obtidas para os diferentes cenários permitiram avaliar o efeito que o modelo de dependência espacial, o tamanho do grid de amostragem e o nível de dependência espacial têm na obtenção de predições mais acuradas ao utilizar Krigagem Ordinária.

3.2 Recursos Computacionais

Para execução deste estudo foram utilizados os *softwares* SAS 9.0, ArcGis 10.0 e o Idrisi Taiga 16.0.

- O SAS 9.2: Utilizado para gerar e selecionar as melhores simulações para a realização deste estudo, como também para calcular o índice Kappa de concordância e teste Z, necessários para atingir o objetivo de comparação dos mapas.
- ArcGIS 10.0: Utilizado na realização de toda a análise geoestatística, desde a modelagem do semivariograma, obtenção de mapas de interpolação e das zonas de manejo.
- O Idrisi Taiga 16.0: Utilizado para obtenção das matrizes de erros, através do comando Errmat onde é realizada a comparação dos mapas.

3.3 Comparação entre os mapas temáticos

As comparações foram realizadas utilizando o Índice Kappa (*k*) de concordância (COHEN, 1960) e o coeficiente de correlação linear global, com o objetivo de verificar se existe concordância real entre os mapas, ou se diferem devido a alguma variação casual.

Nos casos onde há forte dependência espacial o mapa de referência é o obtido a partir do modelo Gaussiano; quando há uma moderada dependência espacial tem-se o mapa gerado a partir do modelo Esférico e para o caso onde há fraca dependência espacial definiu-se como mapa de referência aquele obtido pelo modelo exponencial, como especificado na seção 3.1. Para o cálculo do índice Kappa categorizou-se a área em estudo em quatro classes de igual amplitude.

Visando testar estatisticamente os resultados obtidos, e verificar a significância do Índice Kappa foi realizado o teste *Z* a um nível de significância de 1%, calculado através do valor e variância do Índice Kappa (MA e REDMOND, 1995). Os resultados da comparação dos mapas estão apresentados na Analisando os resultados apresentados na Tabela 11, observa-se que os valores dos Índices Kappa ($\hat{\kappa}$) na maioria dos casos foram superiores a 0,80, sendo classificado assim, como uma similaridade muito boa entre os mapas comparados seguindo a classificação sugerida por Fonseca (2000).

Na realização do teste *Z*, rejeitou-se a hipótese nula ($H_0 : \hat{\kappa} = 0$) em todos os casos, podendo-se concluir que há concordância direta e significativa entre os mapas de classificação e os de referência em todos os casos. Se comparado com o valor global da correlação entre os mapas os resultados são muito parecidos com ressalva aos valores da correlação global se mostrar ligeiramente maior que os valores apresentados pelo Kappa.

Tabela 11.

Uma outra maneira de captar as relações bidimencionais das variáveis (passiveis de ser representadas num mapa temático) se dá pelo coeficiente de correlação linear global, apresentados na seção 2.6, neste estudo para o cálculo do coeficiente de correlação geral (r_g), ou seja, correlação entre os mapas temáticos é dado por

$$r_g = \frac{\sum_{i=1}^{N} | r_i |}{N}$$

onde r_i representa a correlação local (por meio dos valores dos pixels) nos quadrantes correspondentes entre os mapas, com $i = 1,2 \ldots N$. *N* representa o número de quadrantes estabelecido para estratificar a área em estudo na intenção de comparar os mapas de forma localizada.

Porém, os resultados apresentados na Tabela 11, são indicadores globais, e como discutido em seções anteriores é frequente a necessidade de avaliar pontualmente essas relações. Para tanto, estabeleceu-se uma grade de separação espacial tal qual o procedimento que é feito na agricultura para a definição de croquis na intenção de fixar talhões de áreas de plantio, zoneamento ecológico, ou mesmo, manejo florestal.

Essa grade que divide a área em áreas menores (talhões), diferente da classificação utilizada para o cálculo do índice Kappa, não interfere em faixas de áreas que apresentam determinadas características de interesse no solo. Este procedimento conserva as intensidades observadas e/ou interpoladas no mapa temático para a variável em estudo, o que facilita substancialmente os esforços dos indivíduos responsáveis pelo manejo agrícola a ser utilizado, dado que desta maneira pode-se enumerar os talhões criando uma espécie de "endereço" para cada um.

4. RESULTADOS E DISCUSSÃO

Neste capítulo apresenta-se, os resultados da análise exploratória dos dados simulados utilizados neste estudo e a discussão sobre os resultados obtidos pela krigagem, ordinária, bem como as comparações entre os diferentes mapas temáticos.

4.1 Análise exploratória

Em análises estatísticas, para um maior entendimento das informações (dados) que serão analisados, faz-se necessária uma abordagem descritiva do conjunto de informações que se dispõe. Essa abordagem consiste na redução, apresentação, análise e interpretação de dados por meio de instrumentos adequados, como quadros, gráficos e tabelas, por exemplo. Em análises de dados espaciais estas abordagens não são diferentes.

O comportamento assimétrico dos dados apesar de não ser um fator limitante à análise geoestatística, pode dificultar o ajuste de modelos de semivariogramas. Um coeficiente de assimetria dos dados entre os valores de 0 e 0,5 não indica a necessidade de transformação, um coeficiente entre 0,5 e 1,0 a transformação em raiz quadrada é a mais recomendável e um coeficiente maior que 1,0, se faz necessário a transformação logarítmica dos dados (GUIMARÃES, 2004; WEBSTER e OLIVER, 2007).

A Tabela 4 apresenta medidas estatísticas dos dados simulados para os diferentes grids (50×50, 100×100 e 150×150) e estrutura de dependência espacial. Nela, verifica-se que os conjuntos de dados simulados utilizados neste estudo não apresentam assimetria, com isso pode-se realizar a análise geoestatística pelo método de krigagem.

Tabela 4: Medidas estatísticas dos dados simulados para os diferentes *grids* (50×50, 100×100 e 150×150) e estrutura de dependência espacial.

Estatística	**Estrutura de Dependência**								
	50×50			100×100			150×150		
	Forte	Moderada	Fraca	Forte	Moderada	Fraca	Forte	Moderada	Fraca
Qtd. Amostras	121	121	121	441	441	441	961	961	961
Média	-1,12	0,48	0,55	0,66	-0,07	-0,09	1,21	-0,33	0,08
Mediana	-1,05	0,44	0,18	0,69	-0,13	-0,15	1,78	-0,37	0,13
Mínimo	-4,89	-4,19	-4,36	-4,82	-5,13	-4,85	-5,10	-6,07	-5,99
Máximo	3,07	4,74	6,37	4,91	4,79	6,14	4,07	5,77	5,78
Quartil inferior	-4,89	-4,19	-4,36	-4,82	-5,13	-4,85	-5,10	-6,07	-5,99
Quartil superior	3,07	4,74	6,37	4,91	4,79	6,14	4,07	5,77	5,78
Variância	3,17	2,99	3,69	5,54	3,89	5,20	5,71	5,31	5,39
Desvio Padrão	1,78	1,73	1,92	2,35	1,97	2,28	2,39	2,30	2,32
Assimetria	0,12	-0,18	0,23	-0,31	0,02	0,14	-0,36	0,04	-0,07

4.2 Ajuste do semivariograma experimental

A Tabela 5 apresenta as estimativas dos parâmetros relativos ao efeito pepita (C_0), patamar (C_0+C_1) e alcance (a) para os modelos de semivariogramas ajustados aos dados com fraca dependencia espacial, *grid* de amostragem e os modelos semivariográficos ajustados. Para os ajustes utilizou-se *lag* (distância entre os pontos) definido automaticamente pelo software utilizado. A Figura 10 representa a forma gráfica dos semivariogramas obtidos.

Tabela 5: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com fraca DE e diferentes *grids*.

Grid	**Modelo**	C_0	$C_0 + C_1$	A
50×50 (121*p*)	Simulado (*Exp*)	**3**	**4**	**15**
	Gau	3,1932	3,7213	12,2154
	Sph	2,9867	3,7181	12,9562
	Exp	2,5240	3,7240	10,9655
100×100 (441*p*)	Simulado (*Exp*)	**3**	**4**	**40**
	Gau	2,3855	3,0218	31,26
	Sph	2,2909	3,0191	34,86
	Exp	2,3857	3,0329	33,64
150×150 (961*p*)	Simulado (*Exp*)	**3**	**4**	**40**
	Gau	2,8721	3,3058	35,3005
	Sph	2,5442	3,2770	33,0792
	Exp	2,5779	3,3241	40,0792

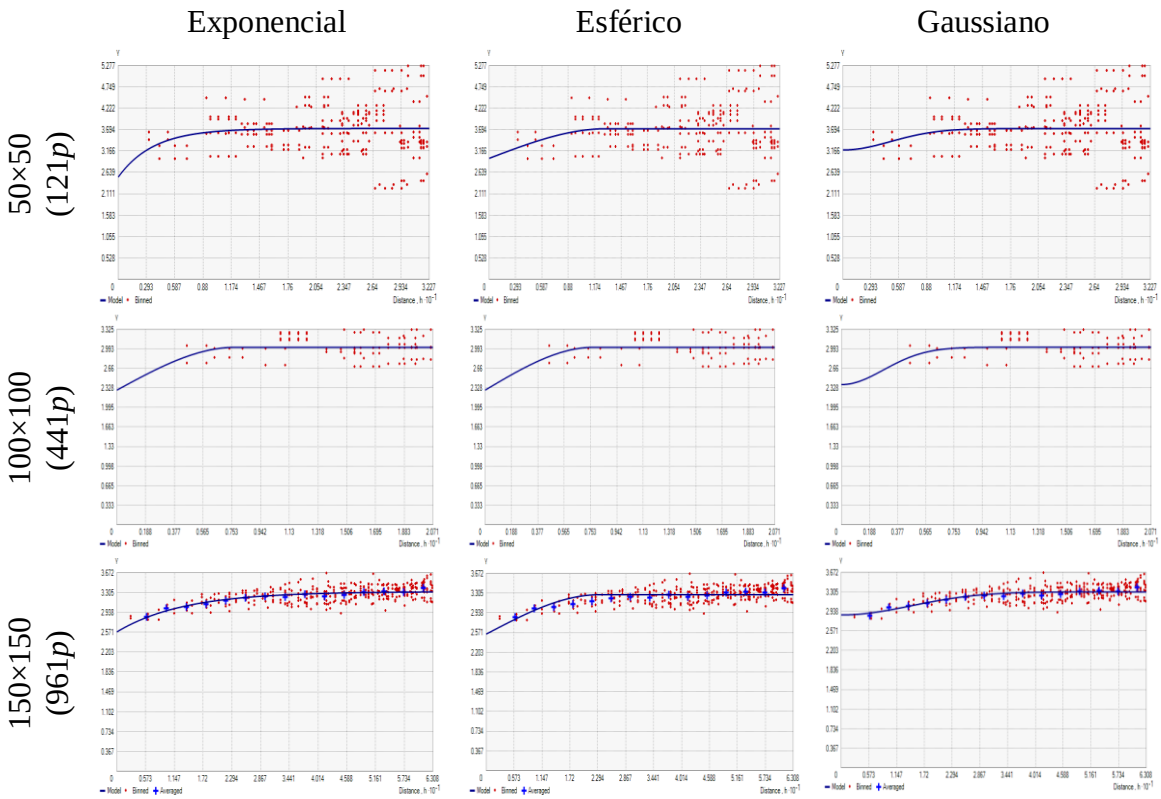

Figura 10: Semivariogramas experimentais e modelos ajustados para os dados com fraca DE.

Pode-se destacar na Tabela 5 que os parâmetros dos modelos ajustados não foram próximos dos valores simulados. Na análise visual dos modelos semivariográficos, observa-se um bom ajuste do modelo exponencial para o grid 150×150, este apresentando patamar bem definido, e no ajuste dos demais modelos não foi alcançado um patamar.

Se comparado os valores das variâncias amostrais apresentados na Tabela 4 com os valores estimados para o patamar contidos na Tabela 5, pode-se verificar que a variância captado pelo modelo é maior que a amostral em todos os modelos para a malha de 50×50, uma justificativa pra esse fato se encontra na dependência espacial fraca incorporada aos dados.

Na Tabela 6 apresenta-se os parâmetros efeito pepita (C_0), patamar (C_1) e alcance (a) para os modelos de semivariogramas ajustados aos dados com moderada dependência espacial, grid de amostragem e os modelos semivariográficos ajustados. Nela pode-se destacar, que os três tipos de modelos utilizados apresentarão alcance extremamente inferiores ao alcance que foi estabelecido na simulação para o grid de 50×50. Porém, se comparados, os

valores de patamar para os modelos no mesmo grid apresentaram valores próximos aos da variância apresentados com os da Tabela 4.

Tabela 6: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com moderada DE e diferentes grids.

Grid	**Modelo**	C_0	$C_0 + C_1$	A
50×50 (121*p*)	Simulado (*Sph*)	**1,5**	**4,5**	**15**
	Gau	1,2690	3,4005	6,0555
	Sph	1,3418	2,9638	6,9420
	Exp	1,8165	3,0067	9,9910
100×100 (441*p*)	Simulado (*Sph*)	**1,5**	**4,5**	**40**
	Gau	1,6649	2,9893	30,2848
	Sph	1,5261	2,9789	38,7961
	Exp	1,0659	3,0361	40,2087
150×150 (961*p*)	Simulado (*Sph*)	**1,5**	**4,5**	**40**
	Gau	2,0942	3,3524	29,1334
	Sph	1,8595	3,3545	34,3300
	Exp	1,7652	3,4772	48,3300

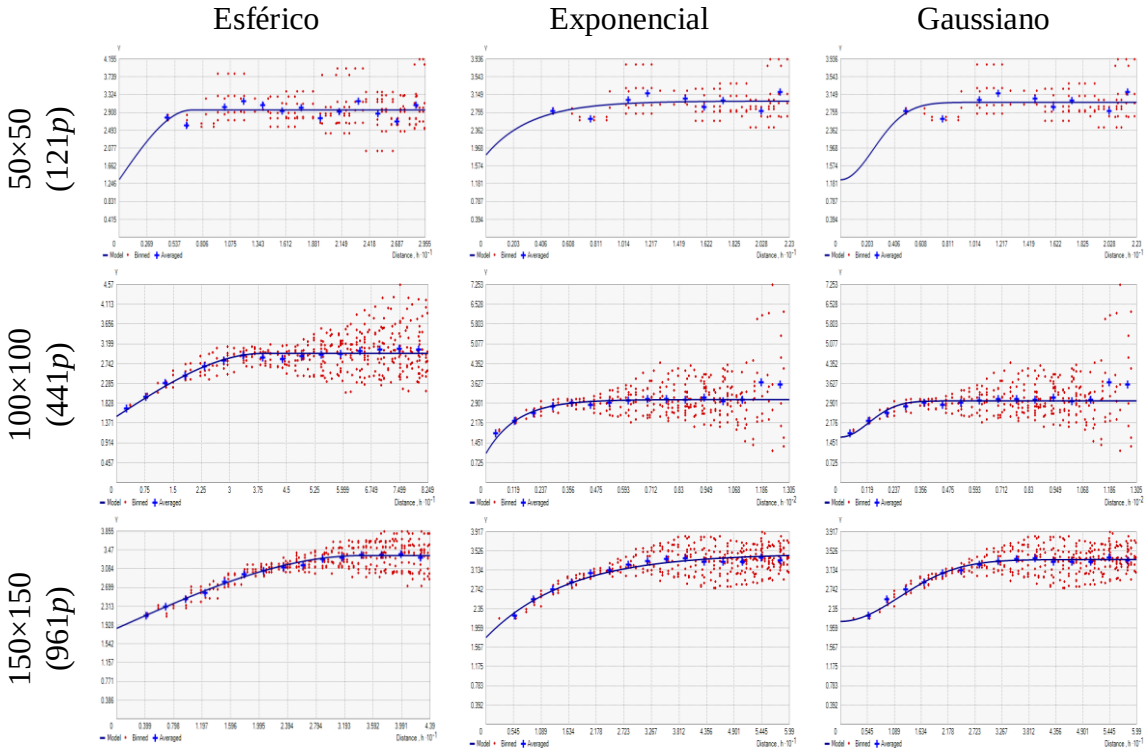

Figura 11: Semivariogramas experimentais e modelos ajustados para os dados com moderada DE.

A Tabela 7 apresenta, os parâmetros dos modelos de semivariogramas ajustados aos dados com forte dependência espacial, grid de amostragem e os modelos semivariográficos ajustados. Nela, pode- destacar que se comparados os valores da variância nos diferentes grds e dependências espaciais contidos na Tabela 4, com os valores de patamar da Tabela 7 pode-se observar que os valores são bem próximo para a maioria dos casos.

Tabela 7: Estimativa dos parâmetros dos modelos semivariográficos ajustados aos dados com forte DE e diferentes grids.

Grid	**Modelo**	C_0	$C_0 + C_1$	***A***
50×50 (121*p*)	Simulado (*Gau*)	**1×10^{-8}**	**3**	**20**
	Gau	0,0040	3,9728	29,7310
	Sph	0,0000	3,8755	38,9180
	Exp	0,0000	3,6916	38,2242
100×100 (441*p*)	Simulado (*Gau*)	**1×10^{-8}**	**3**	**40**
	Gau	0,0054	5,3567	38,4547
	Sph	0,0000	5,6618	38,1821
	Exp	0,0000	5,4615	40, 6997
150×150 (961*p*)	Simulado (*Gau*)	**1×10^{-8}**	**3**	**40**
	Gau	0,0280	5,4370	80,0335
	Sph	0,0000	5,7552	84,2609
	Exp	0,0000	5,1289	83,2609

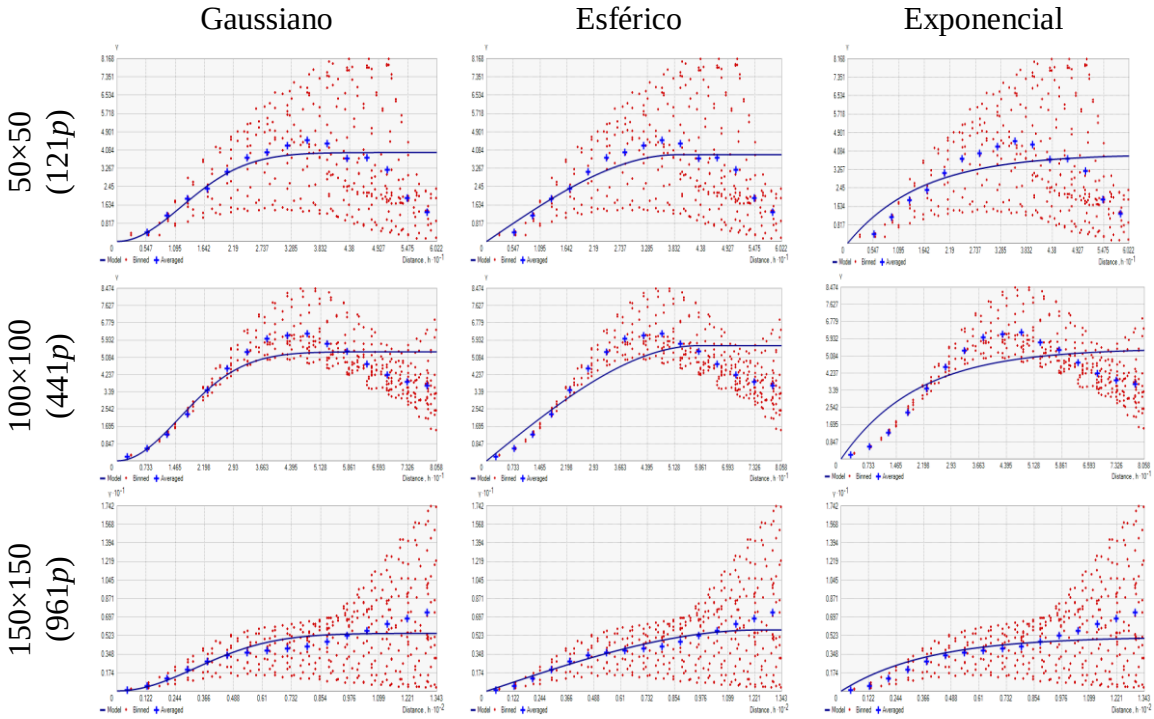

Figura 12: Semivariogramas experimentais e modelos ajustados para os dados com forte DE.

Observa-se na Tabela 7 que os parâmetros efeito pepita dos modelos ajustados se aproximaram dos valores das simulações, e em alguns casos o alcance se aproxima do alcance simulado. Através da inspeção visual (Figura 12) pode-se dizer que a maioria modelos foram bem ajustados.

4.3 Validação

Dado os resultados obtidos por meio da krigagem ordinária aplicou-se o procedimento de validação cruzada ou *cross-validation*[5] (descrito na subseção 2.5.5) para avaliar o desempenho dos modelos ajustados, em termos de precisão das estimativas. Para essa avaliação utilizou-se as seguintes estatísticas: o erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão entre os valores observados e preditos, conforme recomenda VIEIRA (2000).

As Tabelas 7, 8 e 9 são referentes aos resultados obtidos na validação cruzada para os diferentes modelos ajustados em cada conjunto de dados analisados. Nelas observa-se que na maioria dos casos os erros de predição dos modelos ajustados para as diferentes malhas amostrais (50×50; 100×100 e 150×150) e diferentes dependências espaciais (Fraca, Moderada e Forte) foram semelhantes. Considerando como melhor ajuste aqueles que apresentaram ME mais próximo de zero e RMSS mais próximo de 1,segundo recomenda.

[5] ISAAKS e SRIVASTAVA, 1989; WEBSTER e OLIVER, 2001

Tabela 8: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com fraca DE e diferentes grids.

Grid	Modelo	ME	RMSS	$\hat{\beta}_0$	$\hat{\beta}_1$
50×50 (121*p*)	*Gaussiano*	0,041	1,034	0,135	0,046
	Esférico	0,031	1,025	0,135	0,046
	Exponencial	0,031	1,019	0,135	0,046
100×100 (441*p*)	*Gaussiano*	0,009	0,885	0,979	0,085
	Esférico	0,008	0,913	0,979	0,085
	Exponencial	0,012	0,884	0,979	0,085
150×150 (961*p*)	*Gaussiano*	0,003	0,989	0,138	0,138
	Esférico	0,005	1,004	0,128	0,138
	Exponencial	0,004	1,006	0,121	0,138

Tabela 9: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com moderada DE e diferentes grids.

Grid	Modelo	ME	RMSS	$\hat{\beta}_0$	$\hat{\beta}_1$
50×50 (121*p*)	*Gaussiano*	0,030	0,9810	-0,024	0,373
	Esférico	0,032	0,956	-0,224	0,380
	Exponencial	0,015	0,991	-0,226	0,399
100×100 (441*p*)	*Gaussiano*	0,009	0,944	0,062	0,475
	Esférico	0,008	0,929	0,072	0,479
	Exponencial	0,012	0,957	0,049	0,497
150×150 (961*p*)	*Gaussiano*	0,001	0,994	0,168	0,497
	Esférico	0,002	0,991	0,167	0,502
	Exponencial	0,004	0,984	0,151	0,504

Tabela 10: Erro médio (ME), erro quadrático médio padronizado (RMSS) e coeficientes da regressão da validação cruzada da krigagem ordinária nos dados com forte DE e diferentes grids.

Grid	Modelo	ME	RMSS	$\hat{\beta}_0$	$\hat{\beta}_1$
50×50 (121*p*)	*Gaussiano*	-0,006	0,330	0,081	0,952
	Esférico	-0,002	0,207	0,074	0,949
	Exponencial	0,002	0,183	0,077	0,943
100×100 (441*p*)	*Gaussiano*	-0,009	0,347	0,036	0,942
	Esférico	-0,002	0,237	0,048	0,932
	Exponencial	0,003	0,176	0,054	0,927
150×150 (961*p*)	*Gaussiano*	-0,002	0,157	0,021	0,975
	Esférico	0,004	0,087	0,022	0,979
	Exponencial	0,005	0,062	0,021	0,975

Os ajustes para os dados com forte DE os parâmetros da regressão apresentaram boas estimativas, não apresentando valores de RMSS próximos de 1. Os ajustes para dados com moderada DE e fraca DE apresentaram valores muito próximos de 1, e não apresentando grandes diferenças entre os modelos ajustados levando em cada *grid*. Assim, pode-se perceber que os modelos ajustados em cada grid não apresentam grandes diferenças entre si.

4.4 Mapas temáticos

A partir da técnica de interpolação por krigagem ordinária obteve-se mapas temáticos para os dados dos cenários simulados. Foram gerados um total de 27 mapas temáticos de zonas de manejo, sendo 3 para cada conjunto de dados segundo dependência espacial e grid distintos. Por meio dos mapas apresentados na Figura 13, Figura 14 e Figura 15 pode-se realizar uma comparação visual entre os mapas obtidos.

No caso onde a dependência espacial é forte verifica-se que os mapas gerados, a partir de diferentes modelos semivariográficos, apresentam visualmente comportamento bem semelhante. As diferenças entre os mapas temáticos são extremamente sutis, esse mesmo aspecto quase imperceptível é frequentemente encontrado em situações reais no contexto agrícola, com destaque para agricultura de precisão.

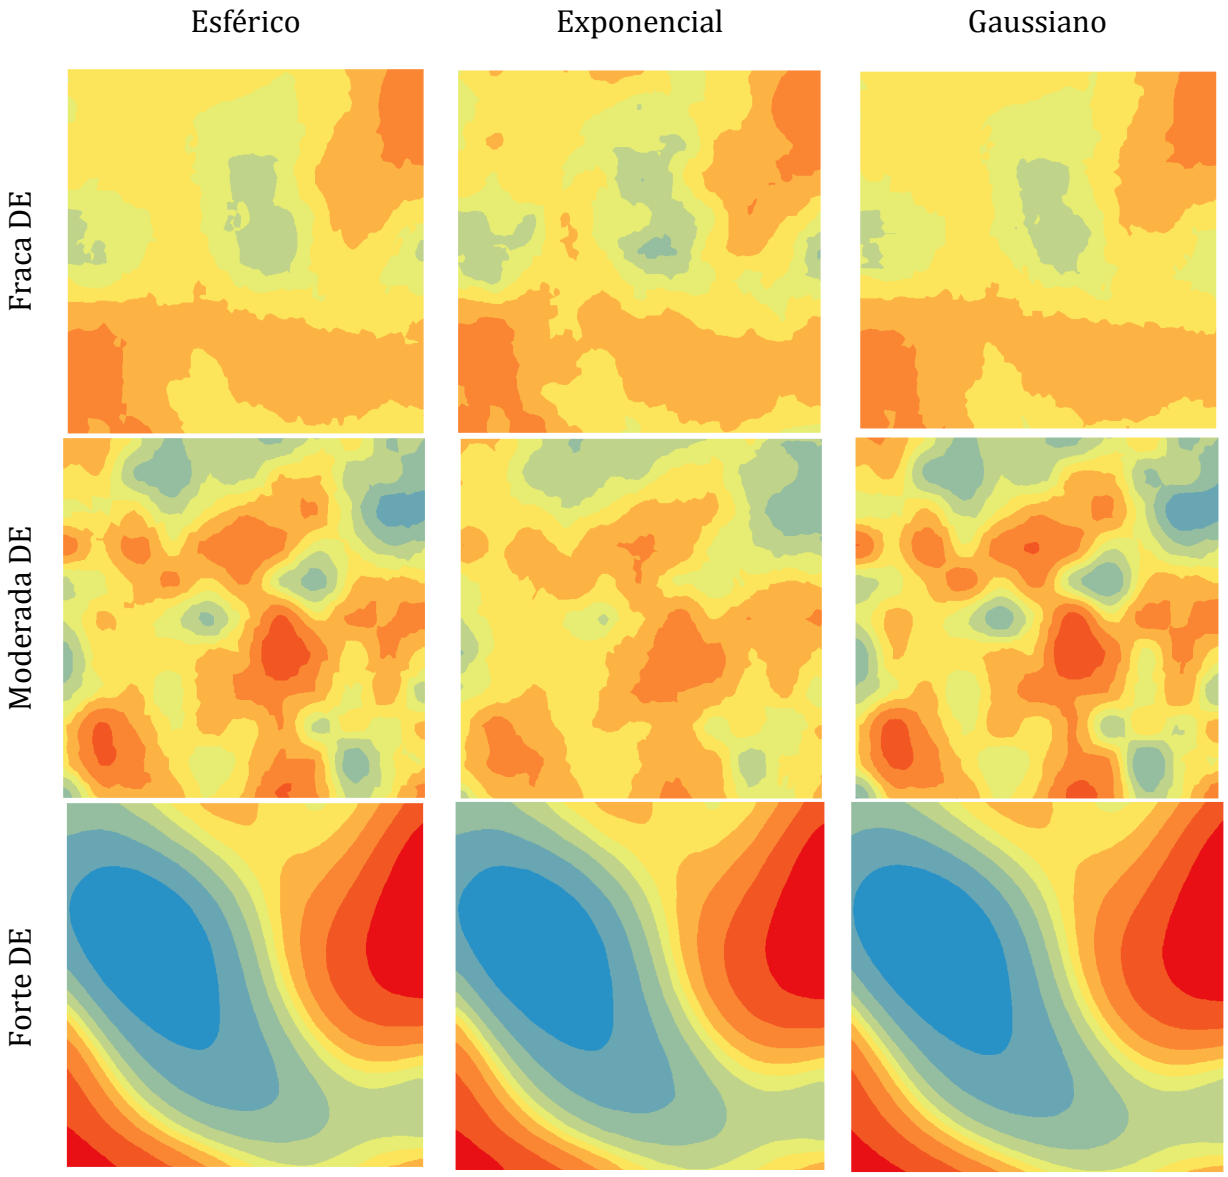

Figura 13: Mapas temáticos para o *grids* de 50×50 e diferente estrutura de dependência espacial (Fraca, moderada e forte).

Os mapas apresentados na Figura 14 são para os casos onde se dispõe de um grid de densidade moderada, grid 100×100. Neste caso é observado um mesmo comportamento apresentado para o grid de densidade menor (50×50). Onde visualmente não observa-se acentuadas diferenças entre os mapas com mesma estrutura de DE.

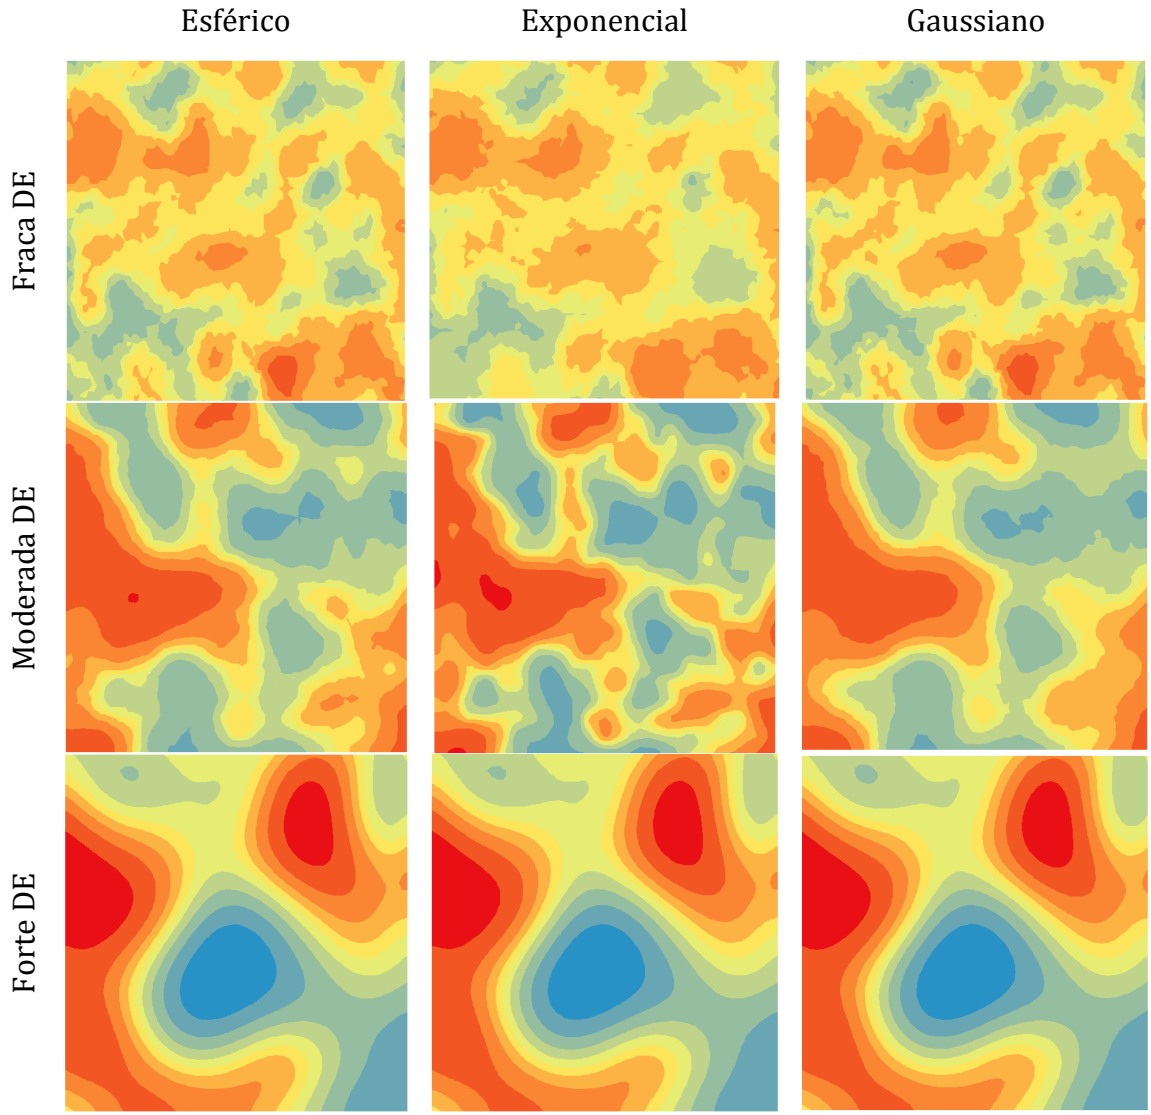

Figura 14: Mapas temáticos para o *grid* de 100×100 e diferente estrutura de dependências espacial (Fraca, moderada e forte).

A Figura 15 apresenta os mapas temáticos para o grid de 150×150 e diferente estrutura de dependências espacial (Fraca, moderada e forte). Nela pode-se observa que os mapas temáticos obtidos para os casos onde o grids de amostragens apresenta alta densidade de pontos e elevada dependência espacial, a diferença entre eles é ainda menor se comparados com os mapas que apresentaram dependência espacial fraca ou moderada.

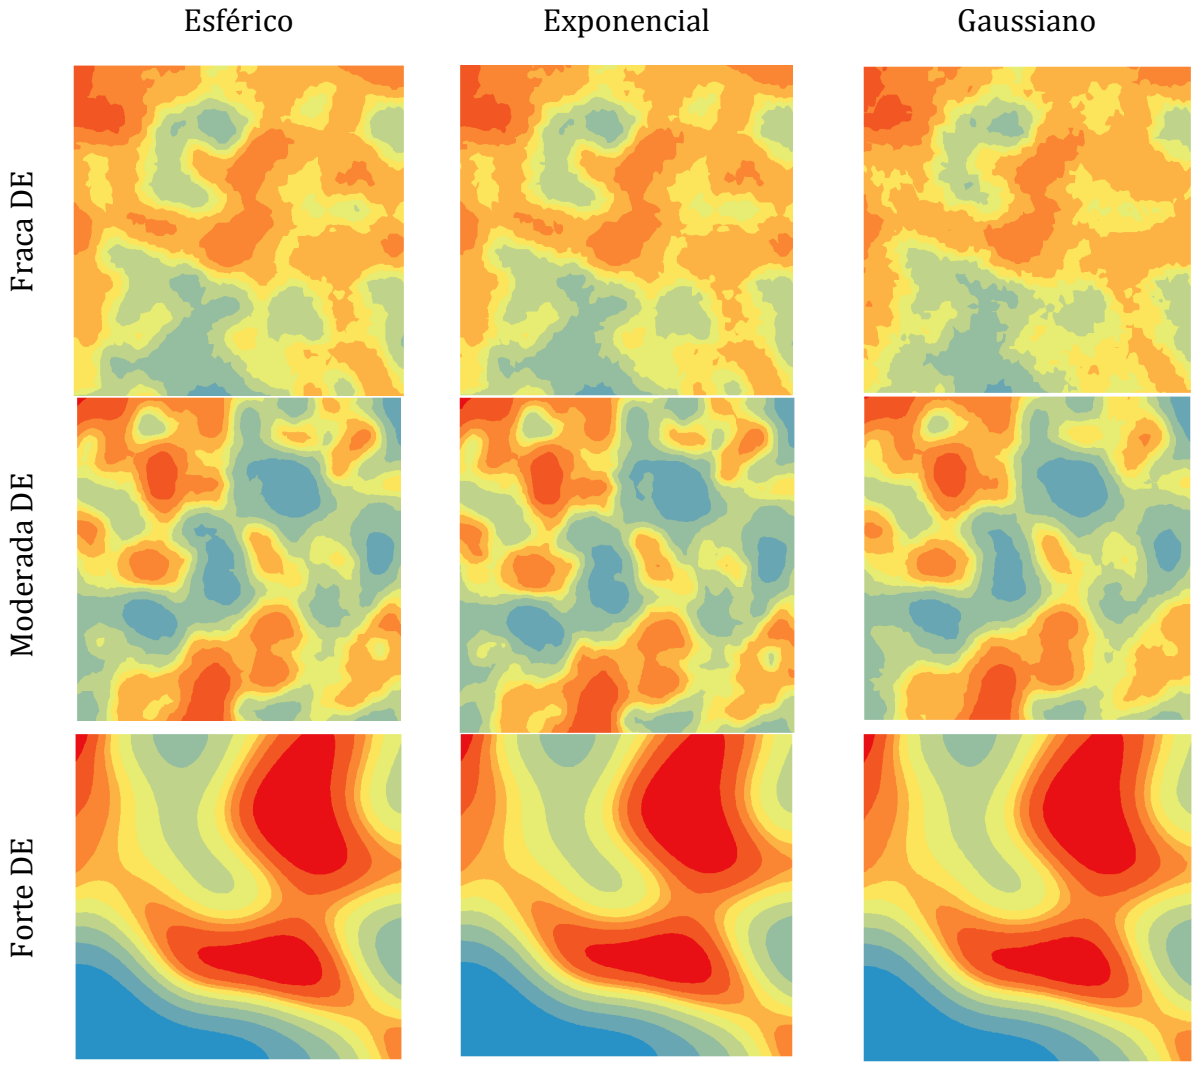

Figura 15: Mapas temáticos para o grid de 150×150 e diferente estrutura de dependências espacial (Fraca, moderada e forte).

Por meio da análise visual dos mapas não é possível quantificar a diferença existente entre os mapas temáticos, apresentados anteriormente, gerados por diferentes modelos de dependência espacial. Para realizar a comparação entre os mapas e quantificar esta diferença é utilizado em geoprocessamento agrícola o uso da conversão dos mapas temáticos em mapas tipo raster ou mapa de pixels, para possibilitar a comparação pixel a pixel dos mapas.

Após a geração dos mapas raster (Anexo II) de cada mapa temático foi realizada a comparação dos mesmos por meio do módulo Errmat do software IDRISI, que gera a matriz de erros (descrita na subseção 2.4.1) e oferece vários resultados estatísticos que indicam se o resultado da classificação é o esperado ou não.

4.5 Comparação entre os mapas temáticos obtidos

Analisando os resultados apresentados na Tabela 11, observa-se que os valores dos Índices Kappa ($\hat{\kappa}$) na maioria dos casos foram superiores a 0,80, sendo classificado assim, como uma similaridade muito boa entre os mapas comparados seguindo a classificação sugerida por Fonseca (2000).

Na realização do teste *Z*, rejeitou-se a hipótese nula ($H_0 : \hat{\kappa} = 0$) em todos os casos, podendo-se concluir que há concordância direta e significativa entre os mapas de classificação e os de referência em todos os casos. Se comparado com o valor global da correlação entre os mapas os resultados são muito parecidos com ressalva aos valores da correlação global se mostrar ligeiramente maior que os valores apresentados pelo Kappa.

Tabela 11: Índice Kappa ($\hat{\kappa}$) de concordância, correlação global (r_g) e *p*-valor segundo *grid* de amostragem e estrutura de dependência espacial.

Modelos Comparados	$\hat{\kappa}$	*p*-valor	r_g	*p*-valor
		Grid 50×50		
Gau_Forte *versus* Esf_Forte	0,992	1×10^{-6}	0,998	1×10^{-08}
Gau_Forte *versus* Exp_Forte	0,990	1×10^{-6}	0,995	1×10^{-08}
Esf_Mod *versus* Exp_Mod	0,778	1×10^{-6}	0,871	1×10^{-08}
Esf_Mod *versus* Gau_Mod	0,924	1×10^{-6}	0,981	1×10^{-08}
Exp_Fraco *versus* Esf_Fraco	0,827	1×10^{-6}	0,924	1×10^{-08}
Exp_Fraco *versus* Gau_Fraco	0,795	1×10^{-6}	0,890	1×10^{-08}
		Grid 100×100		
Gau_Forte *versus* Esf_Forte	0,994	1×10^{-6}	1,000	1×10^{-08}
Gau_Forte *versus* Exp_Forte	0,993	1×10^{-6}	1,000	1×10^{-08}
Esf_Mod *versus* Exp_Mod	0,866	1×10^{-6}	0,925	1×10^{-08}
Esf_Mod *versus* Gau_Mod	0,926	1×10^{-6}	0,976	1×10^{-08}
Exp_Fraco *versus* Esf_Fraco	0,972	1×10^{-6}	0,851	1×10^{-08}
Exp_Fraco *versus* Gau_Fraco	0,946	1×10^{-6}	0,837	1×10^{-08}
		Grid 150×150		
Gau_Forte *versus* Esf_Forte	0,988	1×10^{-6}	0,999	1×10^{-08}
Gau_Forte *versus* Exp_Forte	0,987	1×10^{-6}	0,999	1×10^{-08}
Esf_Mod *versus* Exp_Mod	0,954	1×10^{-6}	0,991	1×10^{-08}
Esf_Mod *versus* Gau_Mod	0,832	1×10^{-6}	0,968	1×10^{-08}
Exp_Fraco *versus* Esf_Fraco	0,962	1×10^{-6}	0,945	1×10^{-08}
Exp_Fraco *versus* Gau_Fraco	0,863	1×10^{-6}	0,995	1×10^{-08}

Nota: Gau_Forte: *Modelo Gaussiano ajustado a dados com forte DE*; Esf_Forte: *Modelo Esferico ajustado a dados com forte DE*; Exp_Forte: *Modelo Exponencial ajustado a dados com forte DE;* Gau_Mod: *Modelo Gaussiano ajustado a dados com Moderada DE;* Esf_Mod: *Modelo Esférico ajustado a dados com Moderada DE;* Exp_Mod: *Modelo Exponencial ajustado a dados com Moderada DE;* Gau_Fraco: *Modelo Gaussiano ajustado a dados com fraca DE;* Esf_Fraco: *Modelo Esférico ajustado a dados com fraca DE;* Exp_Fraco: *Modelo Exponencial ajustado a dados com fraca DE.*

Este resultado se mostra intrigante, tal qual os resultados obtidos por Batista (2012). Porque mostra que não importa muito o modelo ajustado, pois as krigagens foram similares, [no caso de Batista (2012) considerando zonas de manejo].

Faz-se então, importante determinar áreas da forma local que capte qualquer diferença nos mapas uma vez que sabe-se, no contexto do agronegócio, que uma área ainda que relativamente pequena, pode apresentar lucratividade maior se comparada com uma área mais extensa isso se dá por conta da composição de nutrientes presentes na referida área. Assim a aplicação das krigagens poderá ser significativa na detecção dessas áreas.

Para identificar as similaridades entre os mapas de forma localizada, neste estudo, foi utilizado o procedimento descrito na seção 2.3. A Figura 16 representa graficamente o procedimento utilizado.

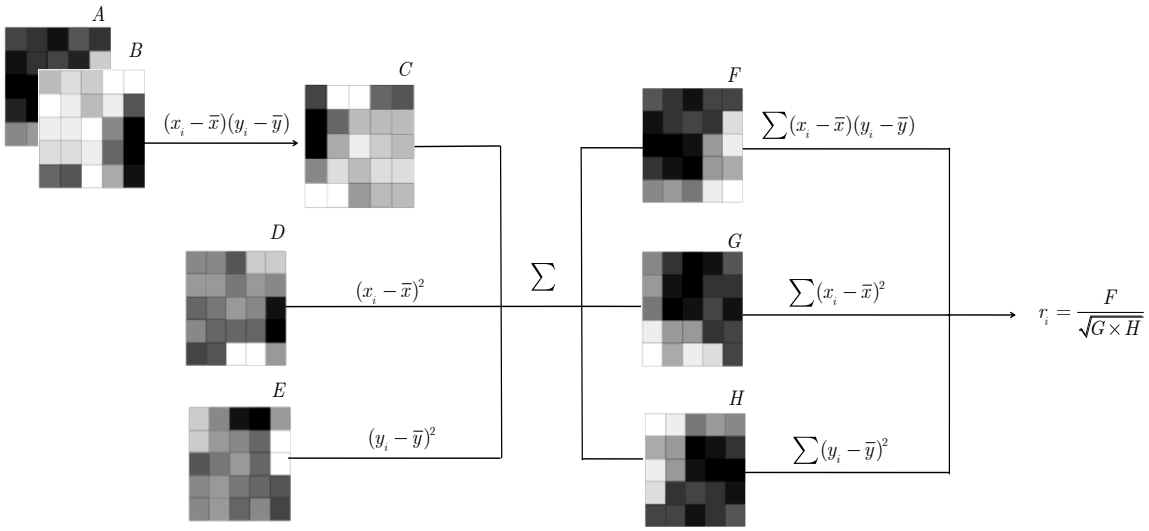

Figura 16: Representação esquemática para a obtenção da correlação local (r_i) entre mapas temáticos.

O coeficiente de correlação de Pearson da maneira que foi utilizado neste estudo faz referencia a associação, similaridade ou concordância entre os mapas temáticos espera-se que a relação de concordância seja linear, sabe-se que essa relação varia de -1 a +1, porém para o cálculo da associação global entre os mapas utiliza-se neste estudo a soma dos valores de correlação local em módulo.

A Figura 17, apresenta os mapas gerados segundo o processo de álgebra de mapas para o caso em que os dados apresentam fraca dependência espacial em cada uma das malhas

utilizadas no estudo (50×50; 100×100 e 150×150). Nela, são destacados alguns valores de correlação fraca positiva de forma local nos mapas, onde, observa-se que o procedimento utilizado neste estudo é capaz de captar o grau de relacionamento entre os mapas temáticos analisados.

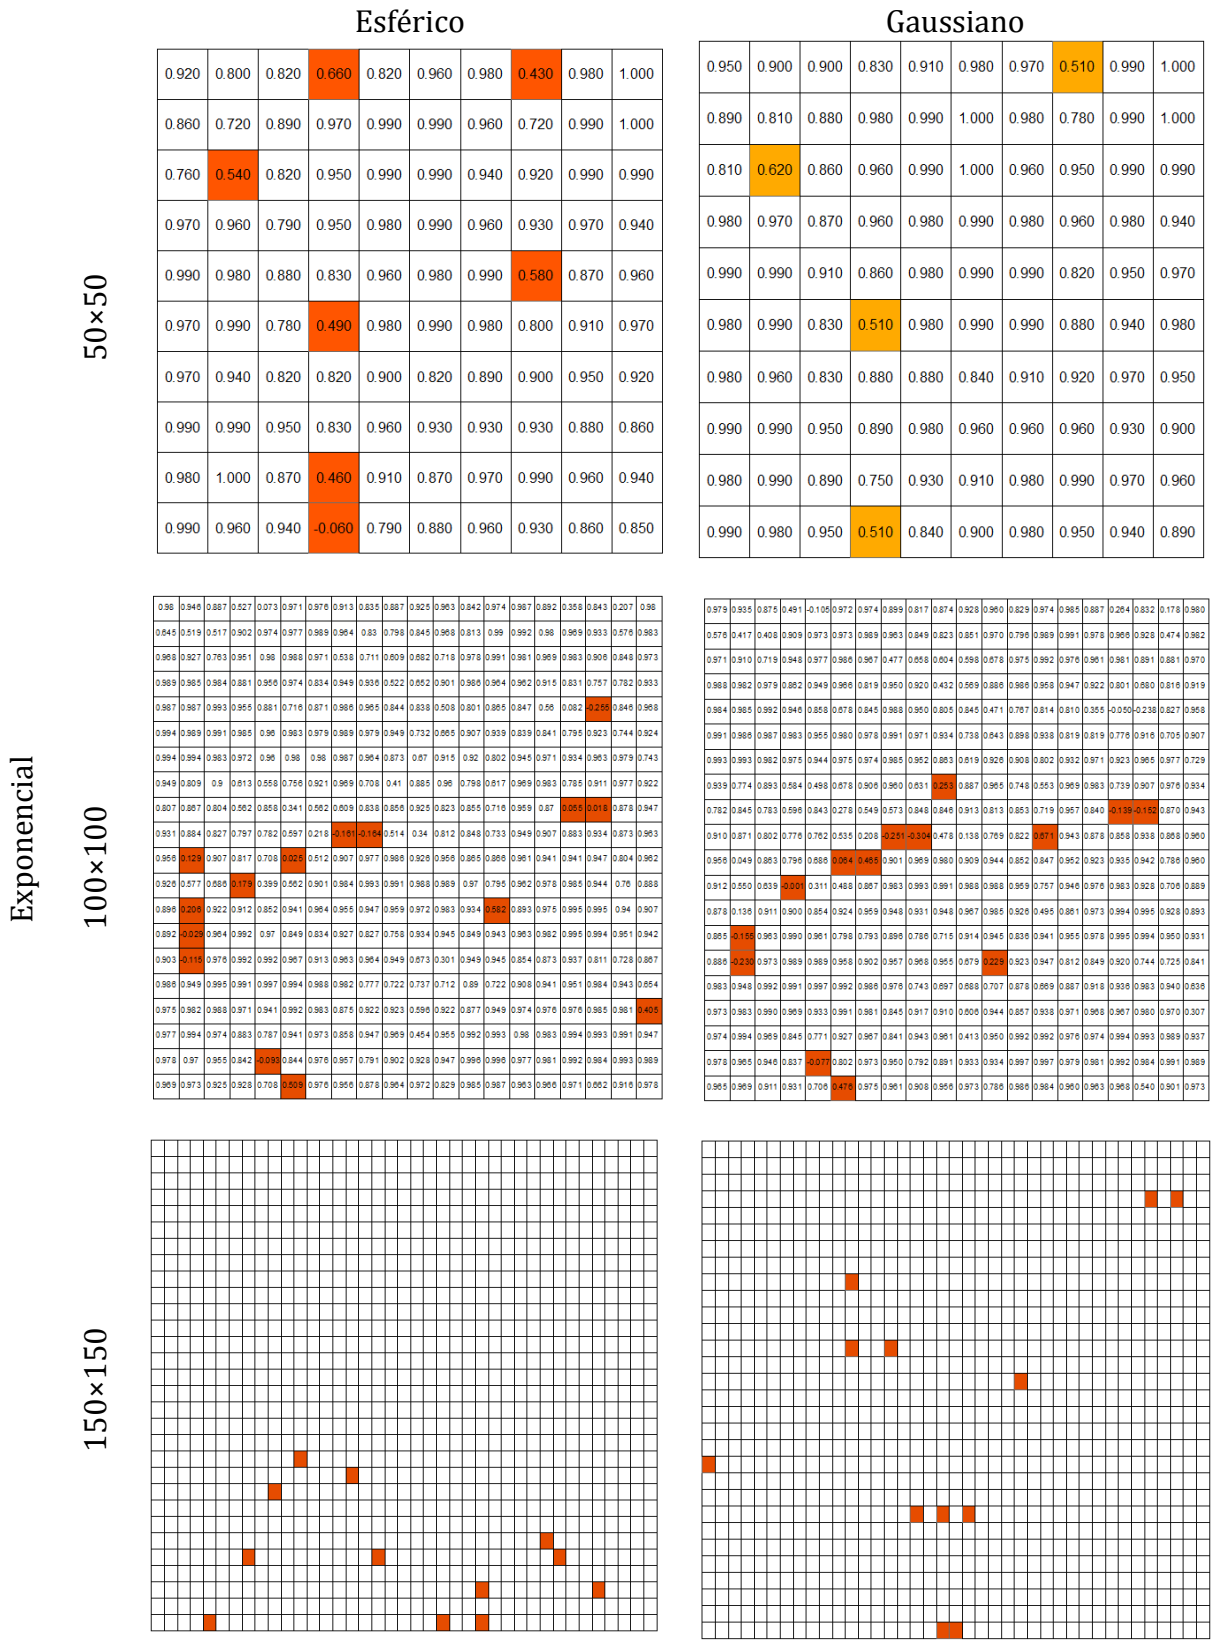

Figura 17: Mapas de correlação local, em diferentes grids, para a comparação entre os mapas temáticos no caso com fraca dependencia espcial.

5. CONCLUSÕES

De acordo com os resultados observados nas comparações dos mapas temáticos utilizados no contexto agrícola, onde empregou-se abordagem geoestatística por meio de krigagem ordinária para diferentes modelos e estrutura de dependência espacial em diferentes malhas (grids) amostrais, verificou-se que uma análise global com a utilização de um índice, a exemplo o Kappa, pode levar a conclusões que desconsiderem o tipo de modelo ajustado levando a um entendimentos equivocado e que contradiz o exposto na literatura especializada, simplesmente por não considerar aspectos de comparações locais.

Em conformidade à necessidade de comparações dos mapas temáticos de forma local para um manejo mais adequado à agricultura de precisão, como discutido ao longo do texto, observou-se que o procedimento utilizado neste estudo atinge os objetivos previamente estabelecidos. Dado que o procedimento por meio de álgebra de mapas para obtenção do coeficiente de correlação local oferece suporte válido e eficaz de comparações entre mapas ou bandas de forma localizada, evidenciando as diferenças mais sutis dos mapas temáticos, aspecto que mesmo com inspeção visual pode não ser detectado prejudicando assim o manejo por agricultura de precisão de áreas destinadas ao plantio.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, M. V. S. Apostila do curso - Introdução ao Generalitat de Valência/ESP (gvSIS). Cap. 1. Viçosa, 2012. EJEAG - Associação Junior de Agrimensura, Centro de Ciências Exatas – UFV.

AGRESTI, A. Categorical data analysis. John Wiley & Sons. New York: New York, 1990.

AGRESTI, A., Categorical Data Analysis, 2nd edition. John Wiley and Sons, 2002.

ANDRIOTTI, J. L. S. Fundamentos de Estatística e Geoestatística. Ed Unisinos. São Leopoldo-RS, 165p. 2003.

ANTUNES, J.F.G.; MERCANTE, E.; ESQUERDO, J.C.D.M.; LAMPARELLI, R.A.C.; ROCHA, J. V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. Pesq. agropec. bras., Brasília, v.47, n.9, p.1288-1294, 2012.

ANTUNIASSI, U.R. Avaliação de sistemas de injeçãode defensivos para utilização em agricultura de precisão. 1999. 87p. Tese (Livre Docência) - Faculdade de Ciências Agronômicas, Universidade Estadual Pulista. Botucatu, 1999.

ARCGIS, 2012. ArcGIS. An overview of the geodatabase. Setembro de 2012. Disponível em:<http://help.arcgis.com/en/arcgisdesktop/10.0/help/index.html#//003n00000006000000 >. Acessado em 15 de janeiro de 2013.

BAILEY, T.C.; GATRELL, A.C. Interactive spatial data analysis in medical geography. Social Science and Medicine, Volume 42, Issue 6, p. 843-855, 1996.

BATALHA, M. O. Gestão agroindustrial. 2. ed. São Paulo: Atlas, 2001.

BATISTA, F. F. Influência de modelos de dependência espacial na definição de mapas temáticos. 2012, p.70 (Mestrado em Estatística Aplicada) - Universidade Federal de Viçosa. Viçosa, MG, 2012.

BUSSAB, O. W.; MORETTIN, A. P. Estatística Básica, 5ª edição, Ed.Saraiva, São Paulo, 2005.

CALLADO, A. A. C. Agronegócio. 1. ed. São Paulo: Atlas, 2006.

CÂMARA, G., MONTEIRO, A. M. V., DRUCK, S., CARVALHO, M. S. Análise Espacial de Dados Geográficos. INPE/EMBRAPA/FIOCRUZ/USP. 2000. Disponível em: http://www.dpi.inpe.br/gilberto/livro/analise/index.html. Acessado em 02/04/2003

CARGO, E. C. G. Desenvolvimento, implementação e teste deprocedimentos geoestatísticos (Krigagem) no sistema de processamento de informações georreferenciadas (SPRING). Cap. 2. São José dos Campos, 1997 – Ministério da Ciência e Tecnologia – INPE.

CARR, P. M.; CARLSON, G. R.; JACOBSON, J. S.; NIELSON, G. A.; SKOGLEY, E. O. Farming fields, not soils: A strategy for increasing fertilizer profitability. Journal of Production Agriculture, Madison, v. 4, p. 57-61, 1991.

CASELLA,G.;ABERGER,R.L. Inferência Estatística. Tradução da 2ª edição Norte-Americana. Tradução Solage Aparecida Visconte,-2ª Ed. CENGAGE Learning, 2010.

CHRISMAN, N. Exploring Geographic Information Systems. J Wiley and sons, New York. A very readable and personal view of GIS.Obtido em Glossary for Exploring GIS, by Nicholas Chrisman. Acessado em Dezembro 2012, disponível em: http://www.wiley.com/college/chrisman/glossary.html

CICCHETTI, D.V. & FLEISS, J.L. Comparison of the nulldistributions of weighted kappa and the C ordinal statistic. Appl. Psychol. Meas., 1: 195-201, 1977.

CICCHETTI, D.V. Testing the normal approximation and minimal sample size requirements of weighted kappa when the number of categories is large. Appl. Psychol. Meas., 5: 101-4, 1981.

COELHO, A.M. Agricultura de Precisão: manejo da variabilidade espacial e temporal dos solos e culturas. Sete Lagoas: Embrapa Milho e Sorgo, 2005. 60 p. (Documentos / Embrapa Milho e Sorgo; 46).

COHEN, J. A coeficient of agreement for nominal scales. Educ. Psychol. Meas., 20: 37-46, 1960.

COHEN, J. Weighted kappa: nominal scale agreement with provision for scaled disagreement or partial credit. Psychol. Bull.,70: 213-20, 1968.

CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: Principles and practices. New York: Lewis Publishers, 1999. 137p.

CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: Principles and practices. New York: Lewis Publishers, 1999. 137p.

CONGALTON, R.G, GREEN, K.; Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, 2nd edition. 2009.

CONGALTON, R.G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. New York: Lewis Publishers, 137p. 1999.

CONOVER, W. J. Practical nonparametric statistics. New York: Wiley, 3rd ed. 1999.

CRESSIE, N. A. Statistics for Spatial Data, revised edition, by N. Cressie. Wiley, NY, 1993 (900pp.) [Original edition was published in 1991.]

DE WIT, A.J.W.; CLEVERS, J.G.P.W. Efficiency and accuracy of per‐field classification for operational crop mapping. International Journal of Remote Sensing, v.25, p.4091‐4112, 2004.

DRUCK, S.; CARVALHO, M.S.; CÂMARA, G.; MONTEIRO, A.V.M. (eds). Análise Espacial de Dados Geográficos. Brasília, EMBRAPA, 2004.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 5755-5762.

FIGUEIREDO, G. C. Exatidão posicional e temática de imagens orbitais. Viçosa, 2007. 87f. Dissertação (Mestrado). Ciências Exatas e Tecnológicas – Departamento de Engenharia Civil, Universidade Federal de Viçosa. Viçosa, 2007.

FLEISS, J. L.; COHEN, J.; EVERITT, B. S. Large sample standard erros of kappa and weighted kappa. Psychol. Bull.,72: 323-7, 1969.

FONSECA, L. M. G. Processamento digital de imagens. Instituto Nacional de Pesquisas Espaciais (INPE), p.105, 2000.

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

FRAISSE, C. Agricultura de Precisão: a tecnologia de GIS/GPS chega às fazendas. Revista Fator GIS, Curitiba, n. 21, p. 28-33, 1998.

GONZALES, Rafael C. WOODS, Richard E. Processamento de imagens digitais. Trad. de Roberto Marcondes Cesar Junior. São Paulo : Edgard Blücher Ltda, 1992.

HUIJBREGTS, C.J. Regionalized variables and quantitative analysis of spatial data. In: DAVIS, J.C. & MCCULLAGH, M.J. eds. Display and analysis of spatial data. New York, John Wiley, 1975. p.38-53.

ISAAKS, E.H., SRIVASTAVA, M. An introduction to applied geostatistics. Oxford Univ. Press., New York, 1989.

JOLY, F. A cartografia. [trad. Tânia Pellegrini] Campinas: Papirus, 1990.

JUPP, D.L.B. The stability of global estimates from confusion matrices. International Journal of Remote Sensing, v.10, p.1563-1569, 1989.

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

LEVINE, John. Programing for graphics files in C and C++. New York: Wiley, 1993

LOURENÇO, J. C.; LIMA, C. E. B. Evolução do agronegócio brasileiro, desafios e perspectivas. En Observatorio de la Economía Latinoamericana, n. 118, 2009. Acesso em Dezembro de 2012. Disponível em: http://www.eumed.net/cursecon/ecolat/br/.

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

MATHERON, G. Principles of geostatistics. Economic Geology, 58 (8): 1246-1266, Dec. 1963.

MOOD, A. M.; GRAYBILL, F. A.; BOES, D. C. Introduction to the Theory of Statistics. McGraw-Hill. 577 p. 1974.

MULLA, D. J.; SCHEPERS, J. S. Key process and properties for site-specific soil and crop management. In: PIERCE, F. J.; SADLER, E. J. (Ed.) The state of site-specific management for agriculture. Madison: ASA: CSSA: SSSA, 1997. p. 1-18.

ORMOND, J. G. P. Glossário de termos usados em atividades agropecuárias, florestais e ciências ambientais. Rio de Janeiro : BNDES, p. 316, 2006.

PEÑA-BARAGÁN, J.M.; NGUGI, M.K.; PLANT, R.E.; SIX, J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. Remote Sensing of Environment, v.115, p.1301-1316, 2011.

PIERCE, F. J.; NOWAK, P. Aspects of precision agriculture. Advances in Agronomy, San Diego, v. 67, p. 1-85, 1999.

PIERCE, F. J.; SADLER, E. J. (Ed.). The State of Site-Specific Management for Agriculture. Madison: ASA: CSSA: SSSA, 1997. p. 245-281. (ASA. Micellaneous Publication).

PYERS, C. E. Evaluation of the intervening opportunities trip distribution model. 44th Anual Meeting of the Highway Research Board, Washington. 1965.

RAMOS, E. M. L. S.; ALMEIDA, S. dos S.; ARAÚJO, A. dos R. Controle estatístico da qualidade. Porto Alegre: Bookman, 160 p., 2013.

REICHENBERG, I.; RUSSNOGLE, J. Farming by foot. Farmer's Journal, v. 113, p.11-15, 1989.

SANTOS, G. R dos. Hierarquização geométrica dos preditores geoestatísticos. 2010. Tese (Doutorado) – Universidade Federal de Lavras, MG. 2010.

SAS Institute Inc., SAS/STAT® User's Guide, Version 9, Cary, NC: SAS Institute Inc., 1999. Licenciado pela Universidade Federal de Viçosa em 2012.

SAWYER, J. F. Concepts of variable rate technology with considerations for fertilizer application. Journal of Agricultural Science, Cambridge, v. 7, p. 195-201, 1994.

SCHUELLER, J. K. In-field site-específic crop production. In: Automated agriculture for the 21st century symposium, 1991, Chicago. Proceedings... St. Joseph: ASAE, 1991. p. 291-292. (ASAE. Publication, 11-91).

SERRA, P.; PONS, X. Monitoring farmer's decisions on Mediterranean irrigated crops using satellite image time series. International Journal of Remote Sensing, v.29, p.2293‑2316, 2008.

SIEGEL, S.; CASTELLAN, N. Nonparametric Statistics for the Behavioral Sciences. 2.ed. New York: McGraw-Hill, 1988. p 284-285.

SILVA, A. B. Sistema de informações geo-referenciadas: conceitos e fundamentos. Campinas - SP: Editora da Unicamp, p. 235, 2003.

SILVA, A. F.; QUARTEZANI, W. Z.; ZIMBACK, C. R. L.; LANDIM, P. M. B. Aplicação da geoestatística em ciências agrárias. Botucatu: FEPAF, 2011. Universidade Estadual Paulista, Botucatu, 136 p. 2011.

SILVA, G. C. Aplicação da Geoestatística Usando a Predição Espacial de Monóxido de Carbono pelo Tráfego Veicular Urbano. 2006. Tese (Doutorado) Universidade Federal de Santa Catarina, Florianópolis, SC, 2006.

THOMPSON, J. R. Estimation equation for kappa statistics. Statistics in Medicine, 20: 2895-2906. 2001.

VIEIRA, C. A. O. Accuracy of remotaly sensing classification of agricultural crops: a comparative study. 2000. 327p. Thesis (Doctor of Philosophy). University of Nottingham, 2000, p. 128-175.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In. NOVAES, R. F.; ALVAREZ V., V. H.; SCHAEFER, C. E G. R. Tópicos em ciências do solo. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000. v.1. p.2-54.

YAMAMOTO, J. K. Avaliação e classificação de reservas minerais. São Paulo: Editora da Universidade de São Paulo, p. 227, 2001.

ZIMBACK, C. R. L. Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade do solo. 2001. 114f. Tese (Livre-Docência) – Faculdade de Ciências Agronômicas, Unesp, Botucatu, 2001.

ANEXOS

ANEXO I

Códigos das rotinas utilizados para as simulações (Software SAS)

- Rotina para malha amostral (*grid*) de 50×50 (121 pontos)

```
TITLE;
TITLE1 'EXPONENTIAL';
TITLE2 'IDE FRACA';

PROC SIM2D OUTSIM=IDE_FRACA;
      SIMULATE
         NUMREAL=300      /*NUMBER OF REALIZATIONS */
         SEED=123456789      /*SEED*/
         SCALE=1                  /*PARTIAL SILL*/
         RANGE=15                   /*RANGE*/
         NUGGET=3               /*NUGGET EFFECT*/
         FORM=EXPONENTIAL       /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                    /*MEAN*/
      GRID
         Y=0 TO 50 BY 5.0
         X=0 TO 50 BY 5.0;
   RUN;
      proc variogram data=IDE_FRACA outvar=sv_Fraca;
         by _iter_;
         compute lagd=5 maxlag=14;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;

TITLE;
TITLE1 'ESFÉRICO';
TITLE2 'IDE MODERADO';

PROC SIM2D OUTSIM=IDE_MODERADO;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*//*
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=15                /*RANGE*/
         NUGGET=1.5               /*NUGGET EFFECT*/
         FORM=SPHERICAL         /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                    /*MEAN*/
      GRID
         Y=0 TO 50 BY 5.0
         X=0 TO 50 BY 5.0;

      proc variogram data=IDE_MODERADO outvar=sv_Moderada;
         by _iter_;
         compute lagd=5 maxlag=14;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

```
TITLE;
TITLE1 'GAUSSIANO';
TITLE2 'IDE FORTE';

PROC SIM2D OUTSIM=IDE_FORTE;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
SEED=123456789            /*SEED*/
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=20                /*RANGE*/
         NUGGET=1E-8               /*NUGGET EFFECT*/
         FORM=GAUSS            /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                   /*MEAN*/
      GRID
         Y=0 TO 50 BY 5.0
         X=0 TO 50 BY 5.0;

      proc variogram data=IDE_FORTE outvar=sv_Forte;
         by _iter_;
         compute lagd=5 maxlag=14;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

- Rotina para malha amostral (*grid*) de 100×100 (441 pontos)

```
TITLE;
TITLE1 'EXPONENCIAL';
TITLE2 'IDE FRACO';

PROC SIM2D OUTSIM=IDE_FRACO;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=1                  /*PARTIAL SILL*/
         RANGE=40                /*RANGE*/
         NUGGET=3               /*NUGGET EFFECT*/
         FORM=EXPONENTIAL            /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                   /*MEAN*/
      GRID
         Y=0 TO 100 BY 5.0
         X=0 TO 100 BY 5.0;
   RUN;

      proc variogram data=IDE_FRACO outvar=sv_Fraco;
         by _iter_;
         compute lagd=5 maxlag=40;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

```
TITLE;
TITLE1 'ESFÉRICO';
TITLE2 'IDE MODERADO';

PROC SIM2D OUTSIM=IDE_MODERADO;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=40                /*RANGE*/
         NUGGET=1.5               /*NUGGET EFFECT*/
         FORM=SPHERICAL            /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                   /*MEAN*/
      GRID
         Y=0 TO 100 BY 5.0
         X=0 TO 100 BY 5.0;
   RUN;

      proc variogram data=IDE_MODERADO outvar=sv_Moderado;
         by _iter_;
         compute lagd=5 maxlag=40;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;



TITLE;
TITLE1 'GAUSSIANO';
TITLE2 'IDE FORTE';

PROC SIM2D OUTSIM=IDE_FORTE;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=23.09               /*RANGE*/
         NUGGET=1E-8               /*NUGGET EFFECT*/
         FORM=GAUSS            /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                   /*MEAN*/
      GRID
         Y=0 TO 100 BY 5.0
         X=0 TO 100 BY 5.0;
   RUN;

      proc variogram data=IDE_FORTE outvar=sv_Forte;
         by _iter_;
         compute lagd=5 maxlag=30;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

- Rotina para malha amostral (*grid*) de 150×150 (961 pontos)

```
TITLE;
TITLE1 'EXPONENTIAL';
TITLE2 'IDE FRACA';

PROC SIM2D OUTSIM=IDE_FRACA;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=1                  /*PARTIAL SILL*/
         RANGE=40                /*RANGE*/
         NUGGET=3               /*NUGGET EFFECT*/
         FORM=EXPONENTIAL           /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                  /*MEAN*/
      GRID
         Y=0 TO 150 BY 5.0
         X=0 TO 150 BY 5.0;
   RUN;

      proc variogram data=IDE_FRACA outvar=sv_Fraca;
         by  iter ;
         compute lagd=5 maxlag=40;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;


TITLE;
TITLE1 'ESFÉRICO';
TITLE2 'IDE MODERADO';

PROC SIM2D OUTSIM=IDE_MODERADO;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=40                /*RANGE*/
         NUGGET=1.5               /*NUGGET EFFECT*/
         FORM=SPHERICAL            /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                  /*MEAN*/
      GRID
         Y=0 TO 150 BY 5.0
         X=0 TO 150 BY 5.0;
   RUN;

      proc variogram data=IDE_MODERADO outvar=sv_Moderado;
         by _iter_;
         compute lagd=5 maxlag=40;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

```
TITLE;
TITLE1 'GAUSSIANO';
TITLE2 'IDE FORTE';

PROC SIM2D OUTSIM=IDE_FORTE;
      SIMULATE
         NUMREAL=300               /*NUMBER OF REALIZATIONS */
         SEED=123456789            /*SEED*/
         SCALE=3                  /*PARTIAL SILL*/
         RANGE=40                /*RANGE*/
         NUGGET=1E-8               /*NUGGET EFFECT*/
         FORM=GAUSS             /*MODELS: GAUSS, EXPONENTIAL E SPHERICAL */
         ;
      MEAN 0.00;                   /*MEAN*/
      GRID
         Y=0 TO 150 BY 5.0
         X=0 TO 150 BY 5.0;
   RUN;

      proc variogram data=IDE_FORTE outvar=sv_Forte;
         by _iter_;
         compute lagd=5 maxlag=30;
         coord xc=gxc yc=gyc;
         var SValue;
         run ;
```

ANEXO II

Operações algébricas mais utilizadas para mapas do tipo *raster*

Quadro 1: Operações pontuais sobre mapas (Geo-campos)

Operação	Descrição Resumida
SOMA SUBTRAÇÃO DIVISÃO MULTIPLICAÇÃO	Gera um geo-campo destino onde o valor resultante em cada posição geográfica é a soma, a subtração, a divisão ou a multiplicação: • do valor na posição geográfica correspondente no geo-campo origem com um valor constante. $Vd_{gi} = V_{0g_i} + \alpha$ $Vd_{gi} = V_{0g_i} - \alpha$ $Vd_{gi} = V_{0g_i} \times \alpha$ $Vd_{gi} = V_{0g_i} \div \alpha$ • dos valores de dois atributos associados à posição geográfica correspondente nos geo-campos origem. $Vd_{gi} = V_0[1]_{g_i} + V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} - V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} \times V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} \div V_0[2]_{g_i}$
COMBINAÇÃO BOOLEANA (CRUZAMENTO)	Gera um geo-campo destino onde o valor em cada posição geográfica é o resultado da aplicação de um operador da lógica booleana (AND, OR, NOT, XOR) sobre os valores dos atributos na mesma posição geográfica dos geo-campos origem.Estas operações são aplicadas sobre geo-campos temáticos $Vd_{gi} = V_0[1]_{g_i} OR\ V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} AND\ V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} NOT\ V_0[2]_{g_i}$ $Vd_{gi} = V_0[1]_{g_i} XOR\ V_0[2]_{g_i}$

Fonte: Adaptado de Câmara (1995).

ANEXO III

Mapas temáticos no formato *Raster*

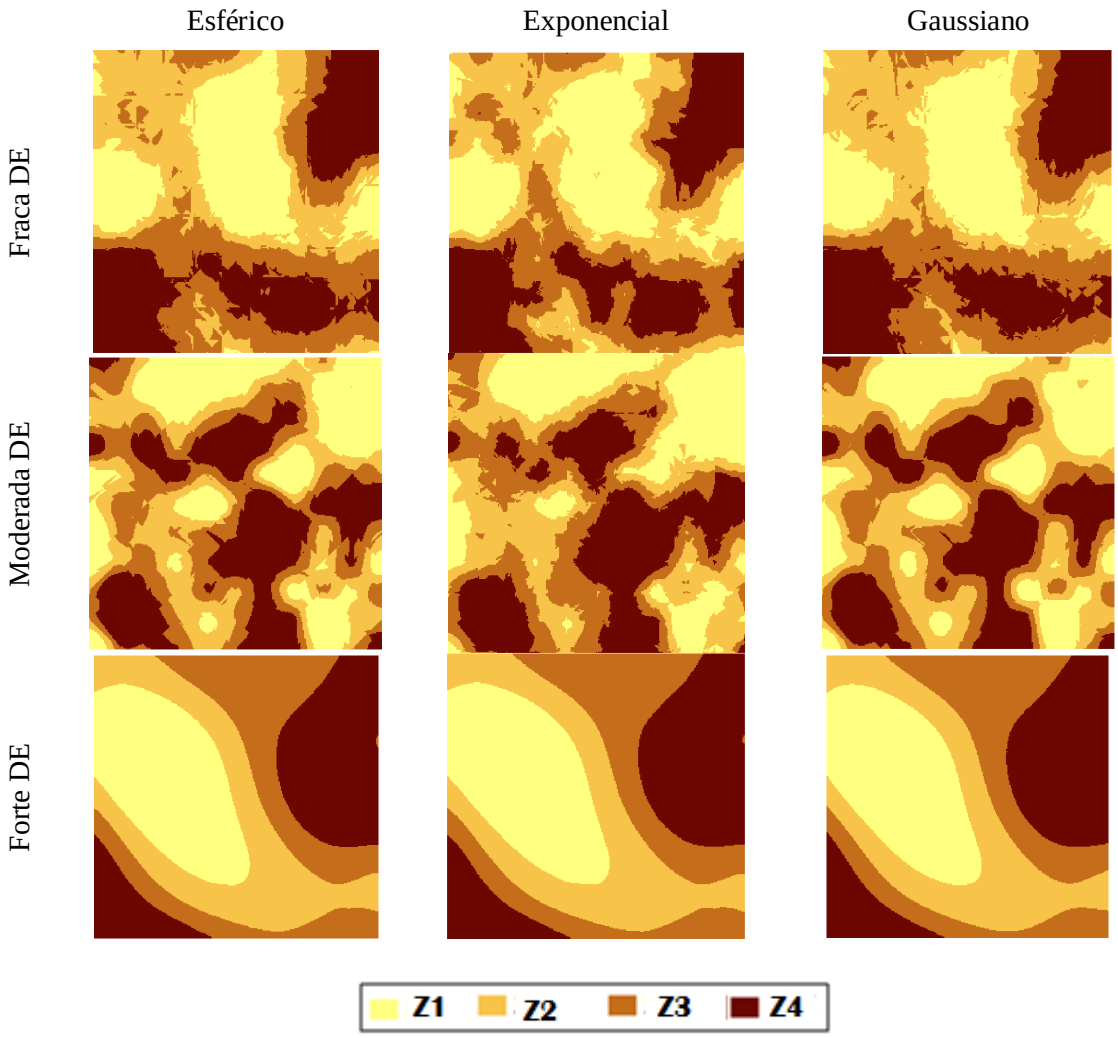

Figura 18 Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 50×50.

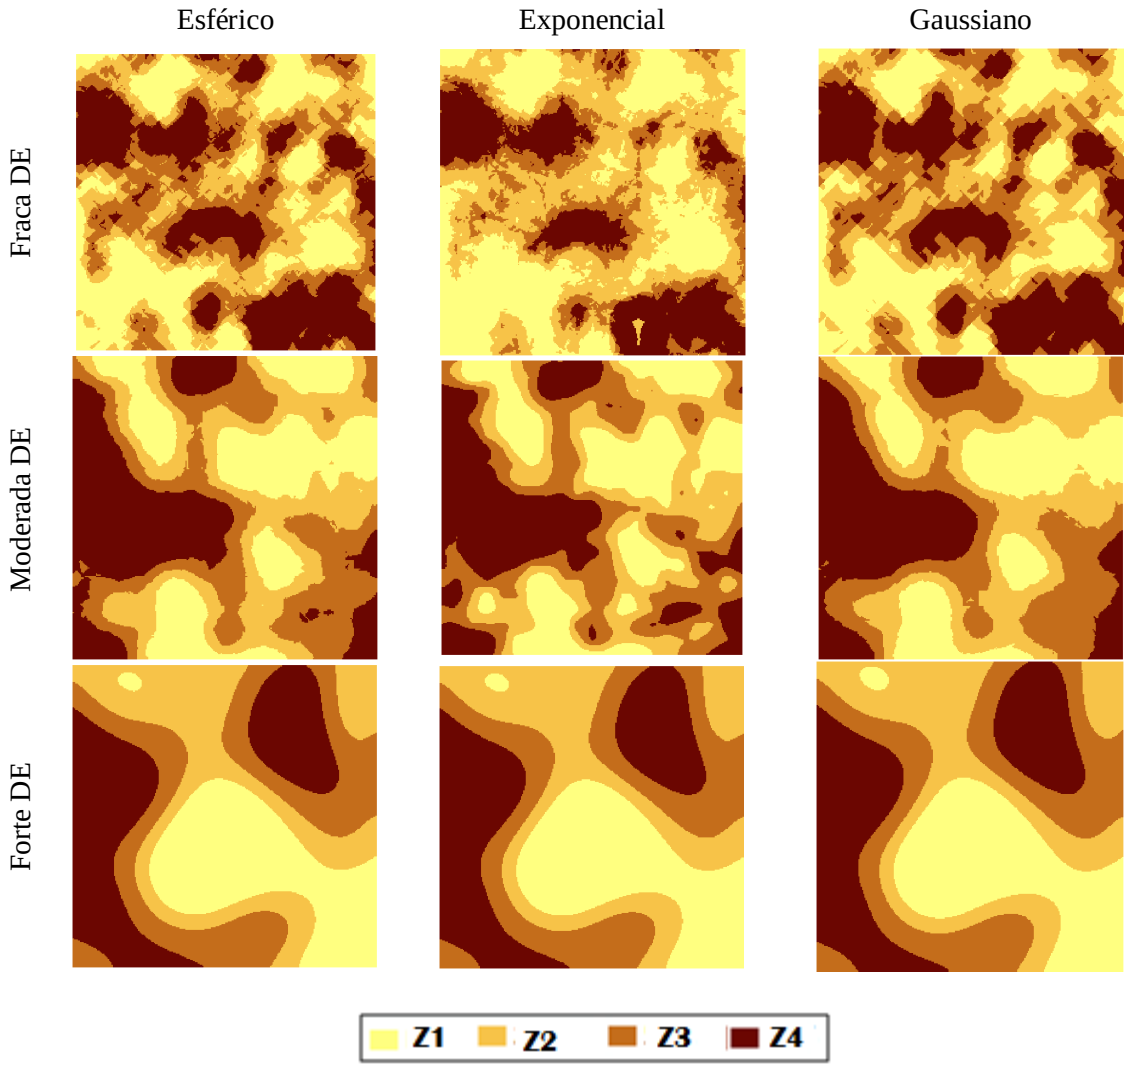

Figura 19: Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 100×100.

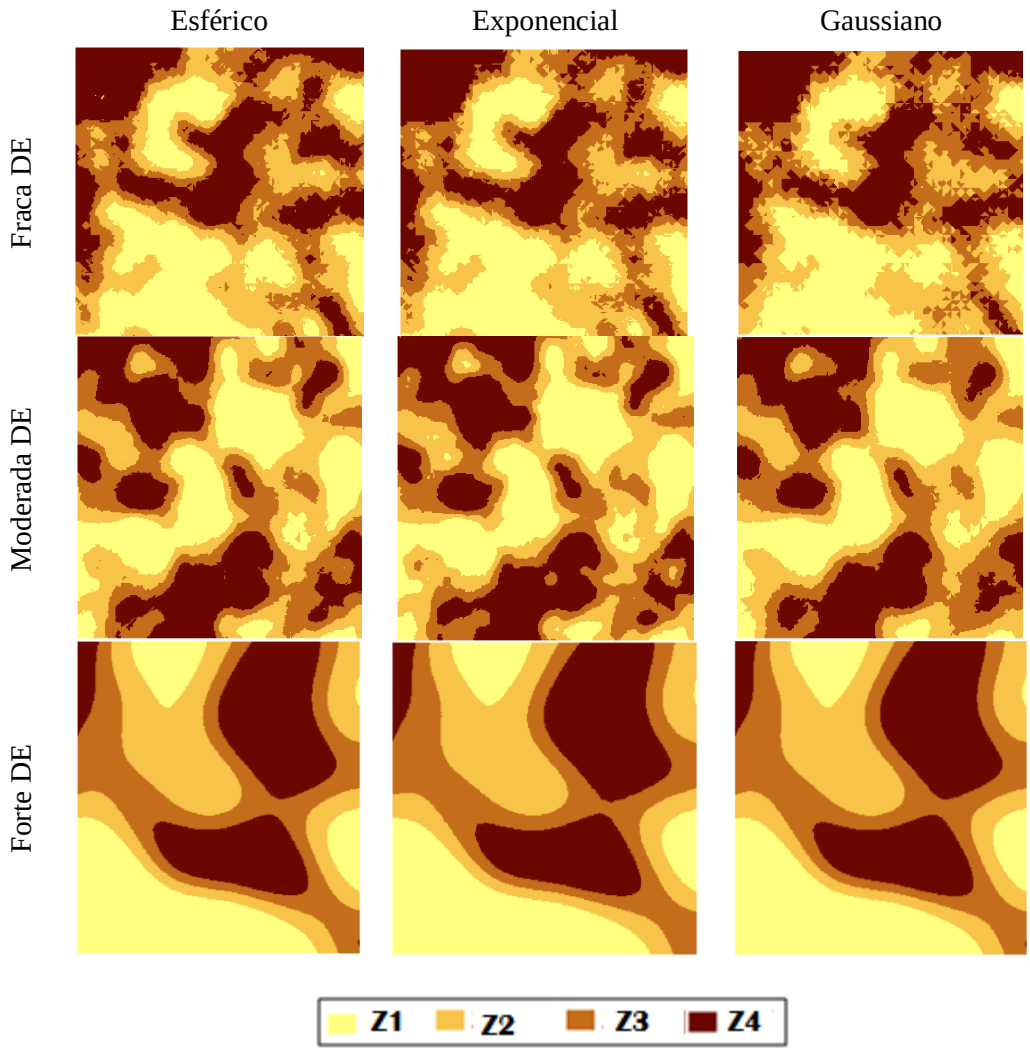

Figura 20: Mapas rasterizados oriundos dos mapas temáticos obtidos por krigagem ordinária para dados que apresentaram os diferentes tipos de dependência espacial em estudo no grid de 150×150.