



Ministério da
Ciência e Tecnologia



INPE-15342-TDI/1378

**ANÁLISE DE RISCO NA FASE DE PLANEJAMENTO
EM SISTEMAS DE PRODUÇÃO AGRÍCOLA POR MEIO
DA SIMULAÇÃO GEOESTATÍSTICA CONDICIONADA**

Jussara de Oliveira Ortiz

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelos Drs. Antonio Miguel Vieira Monteiro e Carlos Alberto Felgueiras,
aprovada em 11 de julho de 2008.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2008/08.05.19.27>>

INPE
São José dos Campos
2008

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3945-6911/6923

Fax: (012) 3945-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO:

Presidente:

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Membros:

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Haroldo Fraga de Campos Velho - Centro de Tecnologias Especiais (CTE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Dr. Ralf Gielow - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr. Wilson Yamaguti - Coordenação Engenharia e Tecnologia Espacial (ETE)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Jefferson Andrade Ancelmo - Serviço de Informação e Documentação (SID)

Simone A. Del-Ducca Barbedo - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Marilúcia Santos Melo Cid - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva e Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Viveca Sant´Ana Lemos - Serviço de Informação e Documentação (SID)



Ministério da
Ciência e Tecnologia



INPE-15342-TDI/1378

**ANÁLISE DE RISCO NA FASE DE PLANEJAMENTO
EM SISTEMAS DE PRODUÇÃO AGRÍCOLA POR MEIO
DA SIMULAÇÃO GEOESTATÍSTICA CONDICIONADA**

Jussara de Oliveira Ortiz

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelos Drs. Antonio Miguel Vieira Monteiro e Carlos Alberto Felgueiras,
aprovada em 11 de julho de 2008.

Registro do documento original:

<http://urlib.net/sid.inpe.br/mtc-m18@80/2008/08.05.19.27>

INPE
São José dos Campos
2008

Dados Internacionais de Catalogação na Publicação (CIP)

O8a Ortiz, Jussara de Oliveira.

Análise de risco na fase de planejamento em sistemas de produção agrícola por meio da simulação geoestatística condicionada/ Jussara de Oliveira Ortiz. – São José dos Campos: INPE, 2008.

181p. ; (INPE-15342-TDI/1378)

1. Simulação geoestatística. 2. Análise de risco. 3. Agricultura de precisão. 4. Planejamento agrícola. 5. Modelagem espacial. 6. Incerteza. I. Título.

CDU 528.711.7

Copyright © 2008 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, microfílmico, reprográfico ou outros, sem a permissão escrita da Editora, com exceção de qualquer material fornecido especificamente no propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2008 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, microfilming, recording or otherwise, without written permission from the Publisher, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de Doutor(a) em
Sensoriamento Remoto

Dr. Camilo Daleles Rennó



Presidente / INPE / SJCampos - SP

Dr. Antonio Miguel Vieira Monteiro



Orientador(a) / INPE / SJCampos - SP

Dr. Carlos Alberto Felgueiras



Orientador(a) / INPE / SJCampos - SP

Dr. Maurício Alves Moreira



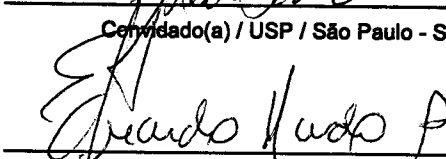
Membro da Banca / INPE / SJCampos - SP

Dr. José Alberto Quintanilha



Convidado(a) / USP / São Paulo - SP

Dr. Eduardo Delgado Assad



Convidado(a) / EMBRAPA / Campinas - SP

Aluno (a): Jussara de Oliveira Ortiz

São José dos Campos, 11 de julho de 2008

“Ser Feliz.....

Ser feliz é reconhecer que vale a pena viver, apesar de todos os desafios....incompreensões....períodos de crise...

Ser feliz é deixar de ser vítima dos problemas e se tornar um autor da própria história.....

É atravessar desertos fora de si, mas ser capaz de encontrar um oásis no recôndito da sua alma...

É agradecer a Deus a cada manhã pelo milagre da vida...

Ser feliz é não ter medo dos próprios sentimentos...

É saber falar de si mesmo...

É ter coragem para ouvir um “não”...

É ter segurança para receber uma crítica...mesmo que injusta...

Pedras no caminho? Guardo todas...um dia vou construir um castelo...”

Fernando Pessoa

Nesses trechos da poesia de Fernando Pessoa parece-me que o poeta falava aos que resolvem buscar um título de doutor, querendo, também, ser esposa, mãe....

É preciso saber retirar as pedras do caminho e torná-las úteis ao nosso amadurecimento. Sem dúvida, o exercício do doutorado é um aprendizado de humildade.

Jussara de Oliveira Ortiz

Dedico este trabalho:

A meu eterno amigo, meu pai, Juraci Gomes de Oliveira (in memoriam) e à minha querida mãe, Maria Ercilia, minha primeira professora, fonte incentivadora sempre.

A meus amados filhos: os caçadores de aventura, Victor e Bruno e à minha meiga borboletinha, Isabella. Vocês se superaram a cada dia desta espera pela mãe que estava fazendo doutorado. Desejo que esta espera não os desanime e sim os encoraje na busca de conhecimento.

AGRADECIMENTOS

Esta Tese pertence em parte a muitas pessoas que, com paciência e apoio sempre revelaram amizade e às quais expresso a minha gratidão.

Ao meu esposo, Manoel Jimenez Ortiz, pela dedicação e carinho com que me ajudou sempre. Nas páginas deste trabalho tem um pouco de você, do seu conhecimento e da sua paciência.

Ao Instituto Nacional de Pesquisas Espaciais, em especial à Divisão de Processamento de Imagens, pelas condições de trabalho proporcionadas e onde me orgulho de ser funcionária.

Aos meus orientadores, Dr. Antônio Miguel Vieira Monteiro e Dr. Carlos Alberto Felgueiras, pela confiança e oportunidade de trabalharmos juntos. Duas personalidades diferentes, que me ensinaram, ao longo deste período, a buscar e aprender, a dar e receber. Duas amizades, onde a maior beneficiada sou eu. Obrigada pelo carinho de vocês, sempre.

Ao meu grande amigo e companheiro de doutorado, Sergio Rosim, pelas incansáveis conversas, leituras pacientes e trocas de idéias sobre meu trabalho.

Às minhas amigas Silvia Leonardi, companheira de sala, com quem eu dividi muitas angústias e alegrias, à Leila Fonseca, por me incentivar sempre, e à Rosimeire Facioli, obrigada pelo seu carinho e por me ajudar a ser perseverante.

Aos meus amigos, Eduardo Camargo, Fábio Furlan Gama e ao Coronel Darcton Policarpo Damião, pelo incentivo e carinho que sempre me dispensaram. Ao Dr. Júlio d'Alge, também pelo incentivo e apoio como amigo e chefe da DPI.

À empresa IMPAR que gentilmente cedeu os dados para que este trabalho se concretizasse. Agradeço em especial ao Eng. Agrônomo William Nolte, por todas as informações que me foram passadas, sempre gentil e atencioso.

A Doutora Suzana Druck, pesquisadora da Embrapa de Brasília, a quem eu devo parte do meu aprendizado e também às boas idéias colocadas para esta Tese, meus sinceros agradecimentos pela disposição em discutir o trabalho, nas vezes em que pudemos estar juntas.

Não posso deixar de agradecer a duas amigas queridas, que indiretamente também participaram desta jornada: minha querida tia Juisvete, por todo seu carinho comigo e com minha família; e à minha companheira no lar, Rosimeire, que há tantos anos se dedica a cuidar de mim e dos meus filhos, como se dela eles fossem. Obrigada.

Às secretárias da DPI, Helen e Luciana, e às secretárias do curso de pós-graduação em Sensoriamento Remoto, Maria Etelvina Rennó e Vera Gabriel da Silva, pela dedicação e responsabilidade.

Quando mencionamos nomes, incorremos no risco de esquecer alguém e, por isso, quero agradecer a todos que, embora não tenham sido mencionados, estiveram presentes comigo durante este percurso.

RESUMO

Esta Tese apresenta uma proposta metodológica para instrumentalizar os processos de planejamento, em sistemas de produção agrícola que utilizam a informação espacializada, com alto nível tecnológico agregado aos Sistemas de Informações Geográficas (SIG). Incorpora a geração de cenários alternativos como base para o suporte à decisão, criados a partir de modelagem espacial, para as estimativas de risco no ciclo de produção. O risco, nesta abordagem, é estimado como uma probabilidade, derivada de modelos de incerteza gerados a partir de procedimentos de geoestatística e tem representação espacial. Sua variabilidade passa a ser um elemento na composição dos cenários alternativos construídos para auxiliar o planejador, acoplados com funções de custos de produção. Os dados que vão compor a informação espacial dos cenários estão disponíveis na forma de amostras georreferenciadas. Deste modo, para efetuar a modelagem espacial é necessário dispor de procedimentos de inferência para espacializar as amostras e gerar superfícies contínuas de representação dos atributos envolvidos. Entretanto, no processo de espacialização ocorrem erros, os quais estão associados a superestimar ou subestimar valores de atributos. Assim, a metodologia apresentada propõe que estes erros derivados dos procedimentos de inferência, sejam considerados e que os impactos ou conseqüências provocadas por cada um deles sejam avaliados com enfoque diferenciado. Estes impactos são refletidos em termos dos custos esperados, usando o conceito de função de perda, e a minimização dos erros e seus impactos são colocados como sendo de interesse do planejador, dependendo dos objetivos que se pretende alcançar. Este trabalho considera a propagação da incerteza, através do método de Monte Carlo, no resultado da modelagem espacial, quando procedimentos geoestatísticos são utilizados para construir a informação espacial, especificamente a simulação seqüencial condicionada, com abordagem não paramétrica ou por indicação. Como demonstração da metodologia, um experimento é conduzido em uma Fazenda do município de Carambeí, Paraná, para planejar, avaliar e indicar quais as áreas exigem colocação de calcário para controlar a acidez e maximizar a produção de trigo. Os resultados do experimento mostram a viabilidade de apresentar a proposta de planejamento para a aplicação de insumos, como um conjunto de alternativas, onde o risco das decisões tomadas e os recursos disponíveis são parâmetros relevantes. Este trabalho apresenta mapas, que representam cenários diferentes para o planejador avaliar, e a escolha das melhores alternativas pode ser auxiliada pelos procedimentos inferenciais adotados. Estes cenários formam um conjunto de alternativas para tomar decisões, composto pelos seguintes parâmetros: ações possíveis de intervenção, impactos ou cenários futuros, viabilidade econômica (se associa a funções de custo) e riscos associados às alternativas propostas.

EMBEDDING RISK ANALYSIS INTO THE PLANNING PHASE FOR AGRICULTURAL PRODUCTION SYSTEMS BY GEOSTATISTICAL CONDITIONAL SIMULATION

ABSTRACT

This Thesis introduces a new methodology for the planning phase in agricultural production systems that make it extensive in order to carry out the spatial modeling. It is necessary to use inferential procedures over the samples to generate a set of continuous surfaces to modelling the spatial variability of the data. However, the inferential procedure, usually an interpolation method, generates estimates of values at non-sampled points, and to these estimates an uncertainty value can be associated to it. As a result of the interpolation process one can superestimate or subestimate the attribute values. The methodology proposed takes into account these uncertainties and the different impacts that they have over the decision process. These impacts are treated here in terms of the expected costs of having one situation or another by making use of the loss function in economic concept. The minimization of the impacts over the production variables is a planner's decision and is entirely dependent upon his production objectives. The approach of this thesis builds uncertainty maps for all the variables involved over the production plan and uses an uncertainty propagation method based on the Monte Carlo simulation and on the spatial modeling of the data and its uncertainty. That is accomplished by a conditional sequential simulation method, using an indicator geostatistical approach, based on the empirical semivariogram function. In order to demonstrate the proposed methodology, an experiment has been carried out on a wheat production system in a farm in Carambeí, Paraná State, Brazil. The experiment conducted encompasses the planning, evaluation and alternative scenarios indication phases considering, just for a demonstrative effect, only the lime as a control variable to the soil acidity. The results show the viability of the proposed method to present the planning phase as a collection of alternatives where the risk of a decision and the available resources observed as variables with a spatial distribution are relevant parameters in decision making process. This work generates maps that represent the different scenarios to be evaluated for the planner and the choice of the best scenario includes a set of actions of possible interventions, the observation of the impacts by generating future scenarios, an assessment of the economic viability (associated to cost functions based on loss functions) and the spatial risks associated to the suggested alternatives.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SIGLAS E ABREVIATURAS

CAPÍTULO 1 - INTRODUÇÃO	23
1.1 Motivação	23
1.2 O Problema	24
1.3 Hipótese deste Trabalho	28
1.4 Solução Proposta: Contribuição desta Tese	29
1.5 Prova de Conceito: O Caso do Sistema de Produção de Trigo em Carambeí, PR	30
1.6 Organização deste Trabalho	31
CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA - INCERTEZA, RISCO E TOMADA DE DECISÃO	33
2.1 Introdução	33
2.1.1 Informação Espacial e o Planejamento na Tomada de Decisão	35
2.1.2 Informação Espacial e Agricultura de Precisão	36
2.2 Abordagem Geoestatística	38
2.2.1 Inferência Espacial e a Incerteza da Informação Espacial	42
2.2.2 Incerteza – Enfoque Paramétrico e Não Paramétrico	44
2.2.2.1 Enfoque Paramétrico – Multigaussiano	45
2.2.2.2 Enfoque Não Paramétrico - Por Indicação	45
2.2.3 Medidas de Incerteza Local	48
2.2.4 Medidas de Incerteza Espacial - Simulação	50
2.2.4.1 Simulação Sequencial Condicionada – Avaliação de Incerteza	53
2.3 Tomada de Decisão Considerando Modelos de Incerteza e Risco	59
CAPÍTULO 3 - MODELAGEM ESPACIAL E TOMADA DE DECISÃO METODOLOGIA PROPOSTA	67
3.1 Introdução	67
3.2 Modelagem Espacial	69
3.2.1 Dados Espaciais	69
3.2.2 Simulação Conjunta de Múltiplas Variáveis	70
3.2.3 Integração das Variáveis e Propagação de Incertezas	73
3.3 Construção de Cenários para Tomada de Decisão	75
CAPÍTULO 4 - DEFINIÇÃO E ANÁLISE DE CENÁRIOS DE RISCO EXPERIMENTO – CORREÇÃO DE ACIDEZ DO SOLO COM CALCÁRIO	87
4.1 Introdução	87
4.2 Experimento	91
4.2.1 Área de Estudo	91

4.2.2 A Calagem no Estado do Paraná	92
4.2.3 Modelo para Estimar a NC	94
4.2.4 Descrição e Disponibilidade dos Dados	96
4.3 Modelagem Espacial para Construção de Cenários de Risco.....	99
4.3.1 Correlação entre as Variáveis	99
4.3.2 Transformação em Principais Componentes	100
4.3.3 Transformação Inversa	104
4.4 Construção de Cenários de Risco para Tomada de Decisão.....	108
4.4.1 Uma Abordagem Comercial.....	109
4.4.2 Alternativas Propostas	111
4.4.2.1 Estimadores Ótimos, Simulação de Monte Carlo e Propagação de Incertezas – Primeira Alternativa	113
4.4.2.2 Risco α (Falso Positivo) e Risco β (Falso Negativo) – Segunda Alternativa	122
4.4.2.3 Impacto Econômico das Classificações de Falsos-Positivos e Falsos-Negativos – Terceira Alternativa	131
4.4.2.4 Definição de Áreas para Planejamento – Alternativa Híbrida.....	142
CAPÍTULO 5 - CONSIDERAÇÕES FINAIS E CONCLUSÕES	153
5.1 Trabalhos Futuros	158
REFERÊNCIAS BIBLIOGRÁFICAS	159
APÊNDICE A – Processo de Krigagem por Indicação para Atributos Contínuos.....	171
APÊNDICE B – Descrição das Amostras.....	173
APÊNDICE C – Transformação para o Espaço das Principais Componentes.....	175

LISTA DE FIGURAS

	Pág.
1.1 – Processo para tomada de decisão com base em modelagem espacial e construção de cenários de risco associados a funções de custo.	29
2.1 - Processo de abstração e inferência	51
2.2 - Síntese do procedimento para construção das fdac para realizar a simulação sequencial por indicação.	55
3.1 – Processo para tomada de decisão com base em modelagem espacial e construção de cenários de risco associados a funções de custo.	68
3.2 - Sequência de processamento para realização da simulação conjunta.	72
3.3 - Integração de campos de atributos numéricos simulados para gerar uma nova variável, Y.	74
3.4 - Escolha do estimador ótimo, pelo planejador, em função do erro inferencial que deseja controlar.	79
3.5 - Associação dos erros de superestimar e subestimar com os riscos $\alpha(u)$ e $\beta(u)$	80
4.1 - Área de Estudo – parte da fazenda Figueira no município de Carambeí, Estado do Paraná.	91
4.2 - Disposição das amostras georreferenciadas, exemplificando alguns dos atributos numéricos das propriedades químicas do solo, apresentadas por ponto.	97
4.3 - Causas de variabilidade na produção e facilidades de intervenção.	99
4.4 - Correlograma Cruzado de PC ₁ e PC ₂	101
4.5 - Ilustração das simulações de PC ₁ e PC ₂ e respectivas construções de suas fdac.	102
4.6 - Variogramas ajustados para: PC ₁ , (a) primeiro corte, ($q_{25\%}$)=116.47, (b) segundo corte ($q_{50\%}$)=129.43 e (c) terceiro corte ($q_{75\%}$)=155.97; PC ₂ , (d) primeiro corte, ($q_{25\%}$)=7.05, (e) segundo corte ($q_{50\%}$)=13.17 e (f) terceiro corte ($q_{75\%}$)=21.39.	103
4.7 - Imagens em níveis de cinza da média e desvio padrão simulados para V%: (a) representação das estimativas de V% por média, simulada a partir das amostras originais; (b) representação das estimativas de V%, simulada a partir da PC e com aplicação da transformada inversa; (c) representação dos desvios padrões das simulações da variável original V%; (d) representação dos desvios padrões das simulações da PC com aplicação da transformada inversa.	105
4.8 - Imagens em níveis de cinza da média e desvio padrão simulados para CTC: (a) representação das estimativas de CTC por média, simulada a partir das amostras originais; (b) representação das estimativas de CTC, simulada a partir da PC e com aplicação da transformada inversa; (c) representação dos desvios padrões das simulações da variável original CTC; (d) representação dos desvios padrões das simulações da PC com aplicação da transformada inversa.	106
4.9 - Etapas utilizadas no planejamento da agricultura de precisão.	109
4.10 - Mapa obtido por procedimento de krigeagem ordinária e que representa as quantidades de calcário a serem colocadas nas áreas indicadas, segundo as faixas definidas na legenda.	111
4.11 - (a) Mapa resultante da modelagem de NC, segundo estimador média; (b) Mapa de incertezas propagadas da modelagem de NC, representadas pelo desvio padrão.	114

4.12 - (a) Mapa de média dos campos simulados e (b) Mapa de incertezas, representadas pelo desvio padrão.	115
4.13 - (a) Mapa resultante da modelagem de NC, segundo estimador $q_{0.7}$; (b) Mapa de incertezas propagadas da modelagem de NC, representadas pelo intervalo de quantis ($q_{.95}$ - $q_{.45}$).....	119
4.14 - (a) Mapa fatiado de NC gerado pelo estimador $q_{70\%}$ e (b) Mapa fatiado de incertezas, geradas pelo intervalo de quantis ($q_{.95}$ - $q_{.45}$).	120
4.15 - Mapas com os estimadores ótimos (a) do quantil inferior, $q_{25\%}$ e (b) mediana, $q_{50\%}$	121
4.16 - Riscos α e β indicando as classificações em função das estimativas para a reposição ou não de calcário no solo.	123
4.17 - Definição dos riscos α e β	123
4.18 - Mapa apresentando áreas de risco α , para $q_{70\%}$	125
4.19 - Mapa indicando áreas de NC média, condicionadas ao risco α , entre 0% e 40%.	128
4.20 - Mapa indicando áreas de NC alta e muito alta: condicionadas ao risco α , somadas entre 0% e 40%.	128
4.21 - Mapa mostrando o risco β com o estimador $q_{70\%}$ (a) e (b) estimador $q_{50\%}$ (mediana), respectivamente.	130
4.22 - Mapas de custo mínimo: (a) funções L_1 e L_2 , (com R\$3.00) e (b) L_1 e L_2 , (com R\$2.00).	135
4.23 - Gráficos de custo mínimo: (a) funções L_1 e L_2 , (R\$3.00) e (b) L_1 e L_2 , (R\$2.00).	136
4.24 - Curva de produtividade do trigo versus colocação de calcário no solo.	137
4.25 - Mapa de custo mínimo utilizando as funções L_1 e $L_{2,1}$, considerando custo de aplicação do calcário constante (R\$28.00) e o preço do Trigo a R\$1.00.	140
4.26 - Mapas de custo mínimo utilizando as funções L_1 e $L_{2,1}$, considerando custo do calcário constante (R\$28.00/ha) e o preço do Trigo variando de R\$3.00 à R\$28.00.	141
4.27 - Ilustração do cálculo das probabilidades acumuladas, segundo em um limiar de NC_{ideal} : (a) $\text{Prob}\{NC(\mathbf{u}_1) = NC_{ideal}\} = 95\%$ e (b) $\{\text{Prob}\{NC(\mathbf{u}_2) = NC_{ideal}\} = 5\%$	143
4.28 - Mapa de Probabilidade da NC_{ideal} exceder 75%.	144
4.29 - Mapa apresentando regiões onde a probabilidade de exceder $NC = 0$ t/ha é maior que 60%.	146
4.30 - Mapa resultante do cruzamento (a) de A_1 com riscos α e (b) de A_2 com riscos α	147
4.31 - Mapa mostrando regiões de risco $\beta = 40\%$ na área definida como A_2	149

LISTA DE TABELAS

	Pág.
3.1 - Avaliação do planejador quanto as possíveis conseqüências dos erros de superestimar e subestimar	80
4.1 - Parâmetros dos semivariogramas de PC_1 e PC_2	104
4.2 - Escala de valores para representar a necessidade de calcário.	111
4.3 - Escala de valores para representar a incerteza no calculo da estimativa de calcário. ...	115
4.4 - Avaliação do planejador quanto as possíveis conseqüências dos erros de superestimar e subestimar	123
4.4 - Descrição dos riscos e conseqüências.	126
4.5 - Resumo do risco α e das possibilidades de decisão.	126
4.6 - Resumo do risco β e das possibilidades de decisão.	130
4.7 - Perda de produção e receita de trigo em função da decisão de não colocar calcário no solo.	139
4.8 - Resumo da perda financeira em função da não colocação de calcário.	141
4.9 - Sugestão de ordenamento dos riscos abordados e suas conseqüências.....	151

LISTA DE SIGLAS E ABREVIATURAS

ATV – Aplicação a taxa variável

fdac – Função de Distribuição Acumulada Condicional

GPS – Global Positioning System

GSLIB – Geostatistical Software Library

Impar – Consultoria e Assessoria Agrícola.

LAT – Latitude

LONG – Longitude

MATLAB – MATrix LABoratory

SPRING – Sistema de Processamento de Informações Georeferenciadas

SSG – Simulação Seqüencial Gaussiana

SSI – Simulação Seqüencial por Indicação

SstoolBox – Modulo do ArcGis para agricultura

VA – Variável Aleatória

VRT – Variable rate technology

CAPÍTULO 1

INTRODUÇÃO

1.1 Motivação

Nos últimos anos o setor agrícola brasileiro vem assistindo uma grande transformação em seus sistemas de produção com a inserção de um alto grau de tecnologias de mapeamento em seus processos de produção. Estas transformações são causadas principalmente por pressões de um mercado consumidor que, cada vez mais globalizado, exige dos produtores um aumento da produtividade sem perda da lucratividade no exercício da atividade agrícola. Este processo contribui para aumentar o grau de participação de novas tecnologias no setor, exigindo uma constante evolução nos métodos e técnicas do planejamento da produção agrícola.

O rápido desenvolvimento das geotecnologias, como Sistemas de Informação Geográfica – SIG, Sistemas de Posicionamento Global – GPS embarcados nos mais diversos artefatos, de celulares a colheitadeiras, Banco de Dados Geográficos, Sensoriamento Remoto orbital entre outras, tem auxiliado a coleta, o armazenamento e o tratamento de dados e informações espaciais de modo mais eficiente. Em particular, nos processos produtivos do setor agrícola, estas tecnologias têm tido grande impacto. A informação localizada passa a ser considerada como mais um insumo no processo produtivo. O segmento da agricultura de precisão em particular, tem se tornado um dos maiores usuários na ligação do planejamento da produção com base no uso extensivo da informação espacializada.

Para o planejamento agrícola, gerar mapas que representem diferentes cenários para definir uma seqüência de ações, em função dos recursos disponíveis e dos riscos aceitáveis, configura uma situação mais interessante para o tomador de decisão, do que, por exemplo, apenas indicar a quantidade de insumo a ser aplicada em cada local. Um mercado de empresas especializadas no planejamento da produção tem surgido no

Brasil. São consultorias que tratam da inteligência de produção agrícola, com grandes clientes no segmento de agricultura de precisão.

Este trabalho se insere no contexto destas novas práticas necessárias ao planejamento, relacionadas à produção em sistemas agrícolas, que apresentam de forma explícita a componente espacial das informações incorporadas ao processo de tomada de decisões. No contexto deste trabalho, decisão é uma escolha entre alternativas construídas no processo de planejamento da produção.

As informações necessárias ao planejamento, em geral, resultam dos dados amostrados que, após organização, adquirem significado no contexto de produção (EHRLICH, 1996) e ao serem disponibilizadas, estas informações propiciam a criação de alternativas de gerenciamento. No entanto, a diversidade de parâmetros e indicadores que definem um planejamento, quer seja para instituições governamentais ou para produtores rurais, requer que esta informação seja apresentada de forma a facilitar as ações que vão modificar ou intervir em fases da produção.

Uma possibilidade de apresentação destas alternativas para intervenções é a geração de cenários de planejamento. Cenários, no contexto desta Tese, são as informações sobre as variáveis e parâmetros envolvidos no sistema de produção, espacializados na forma de mapas. Estes mapas têm a eles associados medidas de incertezas associadas aos processos de espacialização e caracterizam a qualidade das informações geradas para os processos decisórios.

1.2 O Problema

De acordo com o Centro de Gestão e Riscos (QSP, 2004), diante de um contexto de incertezas, quatro atitudes podem ser adotadas:

1. Ignorá-las completamente, o que seria pouco prudente;

2. Tentar evitá-las, através de medidas mitigadoras¹, o que reduz os impactos negativos de eventos incertos, mas não elimina a fonte de riscos;
3. Tentar reduzi-las através de aprofundamento da pesquisa, coleta de mais dados e informações durante a fase de planejamento; algumas incertezas são reduzidas, outras não podem ser eliminadas e, finalmente,
4. Incorporar os riscos e incertezas ao processo de planejamento, para que este possa ser devidamente administrado.

O conceito de *risco* é apresentado na literatura sob diversas definições, das quais seguem algumas:

“...possibilidade de que algo aconteça e gere um impacto sobre os seus objetivos. Refere-se à chance de ganhar ou perder e é medido em termos de probabilidade e conseqüências (QSP-NORMA AS/NZS 4360:2004).”

“...derivado do italiano “*resicare*”, que significa ousar e, neste sentido, é uma opção (BERNSTEIN, 1997).”

“...uma medida de probabilidade de que ocorram danos ou prejuízos em conseqüência da exposição a um perigo ou uma ameaça física, (EUROPEAN COMMISSION, 2001).”

Essencialmente, o conceito do risco está relacionado à idéia de incerteza. O risco está, também, relacionado às escolhas efetuadas, como ser mais ousado, trabalhando com incertezas maiores ou ser mais conservador, apostando em incertezas menores. Mas não se trata de acaso. O risco decorre da incerteza, inerente às possíveis conseqüências de uma escolha, e estas conseqüências podem estar relacionadas a ganhos ou a perdas. Esta noção de ganhar ou perder necessita sempre de um contexto definido, e quando definida especificamente para um problema abordado, torna possível estabelecer funções de custo para as decisões com base nos riscos estimados.

¹ Mitigar significa atenuar o efeito dos riscos (EUROPEAN COMMISSION, 2001)

A idéia de incorporar aos riscos, as incertezas relacionadas aos parâmetros e variáveis presentes no sistema de produção, para uma dada opção de manejo, e a incorporação destas medidas com representação espacial ao processo de planejamento, através da elaboração de cenários associados a funções de custo, é o centro deste trabalho.

Para o caso do planejamento agrícola de uma determinada região, deve-se considerar que a informação tem uma representação espacial e é, por natureza, incompleta. Segundo Goodchild (2001), o que se conhece dos recursos, ou fenômenos em que os atributos ou propriedades se manifestam no espaço, resume-se a um conjunto discreto de amostras² de dados espaciais, de modo que procedimentos de inferência espacial, em locais não amostrados, são necessários para gerar representações contínuas desses fenômenos.

Os sistemas de informações geográficas, SIG, são sistemas que apresentam capacidade de organização, de integração de dados e de análise espacial (BURROUGH e McDONNELL, 1998 & DRUCK et al. 2004). Ao estabelecer modelos matemáticos, determinísticos ou estocásticos para serem executados em ambiente de SIG, que relacionam dados espaciais para representar adequadamente um fenômeno, caracteriza-se a modelagem espacial em SIG (HEUVELINK, 1998). Os SIG possibilitam, desta forma, que as amostras sejam transformadas em informação espacial, através de procedimentos de espacialização e análise espacial (HEUVELINK, 1998; CRUZ, 2000; BÖNISCH, 2001; VISCARRA ROSSEL et al., 2001 e AERTS et al. 2003).

As aplicações dos procedimentos da geoestatística (GOOVAERTS, 1997 & DEUTSH e JOURNAL, 1998), já implementados em alguns SIG como SPRING (CÂMARA, 1996) e ArcGis (ESRI, 2008), para os mapeamentos direcionados ao planejamento de recursos naturais têm colocado em foco a importância da representação da incerteza. A incerteza, em especial a propagação de incertezas em produtos resultantes de modelagem em SIG, tem sido abordada por diversos pesquisadores (BÖNISH, 2001; AERTS et al., 2003; PEARLSTINE & MAZZOTII, 2004; ORTIZ et al., 2004 e CAMARGO et al. 2008)

² Amostras: no contexto deste trabalho, refere-se a um conjunto de dados, observados direta ou indiretamente, e que têm a eles associados atributos, numéricos ou categóricos, e sua posição no espaço geográfico. (FELGUEIRAS, 1999).

devido às conseqüências adversas que podem ocorrer em tomadas de decisão que fazem uso destes produtos.

Os SIG são utilizados para auxiliar as decisões de planejamento, e o tomador de decisões requer informações para administrar o risco e conhecer os diferentes aspectos de uma modelagem obtida por diversas operações em SIG. O objetivo, não é simplesmente navegar no espaço físico e saber onde estão os riscos, mas também, no espaço da decisão, ou seja, avaliar o que pode ser feito para efetivamente reduzir estes riscos. Para tais afirmações, o conhecimento da incerteza na informação e sua propagação são essenciais.

Ao superestimar ou subestimar um valor, o risco de uma decisão fica vinculado a um destes tipos de erro, de tal modo que a escolha da alternativa mais adequada a decisão pode ser auxiliada por procedimentos inferenciais. Estes procedimentos inferenciais devem buscar a minimização de erros em função das conseqüências que cada um deles pode causar diante do problema abordado. Estas conseqüências podem-se associar a custos financeiros que determinem perdas ou ganhos esperados diante da escolha efetuada.

Os erros derivados dos procedimentos inferenciais adotados para espacialização podem ser avaliados a partir de modelos de incerteza, através de uma abordagem geoestatística. Neste caso podem-se caracterizar situações onde se observa uma condição de superestimar ou subestimar o valor de certos atributos. Esta situação vai produzir efeitos diferentes no resultado da modelagem espacial integrada e, portanto, deve ser tratada de acordo com o impacto que cada uma destas situações produz. Para analisar a propagação das incertezas na modelagem espacial, definir e avaliar o impacto dessas incertezas é necessário estimar os riscos associados às representações geradas pelos procedimentos de inferência adotados.

O problema, então, é como produzir uma nova metodologia para dotar o planejador da possibilidade de escolha objetiva entre um conjunto de alternativas possíveis. Observando que estas alternativas construídas têm por base uma medida de risco, estimada a partir das informações espacializadas e com incerteza quantificada.

Observando ainda que funções de custo podem ser associadas a estas estimativas de risco e que o risco, em si, é uma medida de probabilidade e, neste caso específico, com uma representação espacial, e sua variabilidade passa a ser um elemento na composição destes cenários alternativos de produção, em auxílio ao planejador. Como, então, explicitar espacialmente o risco associado a uma decisão no processo de planejamento da produção agrícola? Como apresentar as conseqüências da escolha de uma alternativa, que é um cenário de produção, dentro do conceito de risco apresentado, se a eliminação dos riscos não é possível e é necessário administrá-los adequadamente? E por fim, se o risco espacialmente distribuído é conhecido, como orientar o tomador de decisão para o uso apropriado desta informação?

1.3 Hipótese deste Trabalho

Para responder a estas questões, esta Tese parte das seguintes premissas:

- O produtor deve possuir alto nível tecnológico agregado ao seu processo de produção agrícola e utilizar técnicas de planejamento da produção. Práticas como a realização anual de levantamentos sistemáticos da situação de fertilidade do solo e outras condições ambientais e a realização de coleta de informações sobre a produção através de sistemas georreferenciados, devem ser comuns a estes sistemas de produção;
- Inovação tecnológica neste contexto pode ser viabilizada através do desenvolvimento de novas metodologias capazes de produzir insumos para o processo de planejamento da produção baseado na construção de alternativas de manejo com o uso de uma medida de caracterização espacial dos riscos. Estes riscos apresentam variabilidade espacial, e esta variabilidade impacta os cenários de produção e portanto deve disponibilizado ao tomador de decisão;
- A variabilidade espacial do risco e sua incerteza pode ser determinada a partir de uma abordagem geoestatística baseada na variografia empírica (GOOVAERTS, 1997 e CAMARGO et al., 2008).

Consideradas estas premissas a hipótese desta Tese responde às questões apresentadas na caracterização do problema, afirmando que é possível desenvolver e padronizar uma metodologia para quantificar e qualificar o risco associado aos sistemas de produção agrícola, que fazem uso de informações espacializadas integradas a funções de custo, com componente espacial e a partir do qual, cenários de produção podem ser construídos e avaliados no processo final de tomada de decisão.

1.4 Solução Proposta: Contribuição desta Tese

A Figura 1.1 apresenta, na forma de um diagrama de bloco conceitual, a contribuição desta Tese. Na abordagem proposta a solução divide o problema em duas fases: a modelagem espacial do risco com a quantificação e a propagação das incertezas; e a construção de cenários alternativos de produção. Estas fases estão detalhadas no capítulo 3.

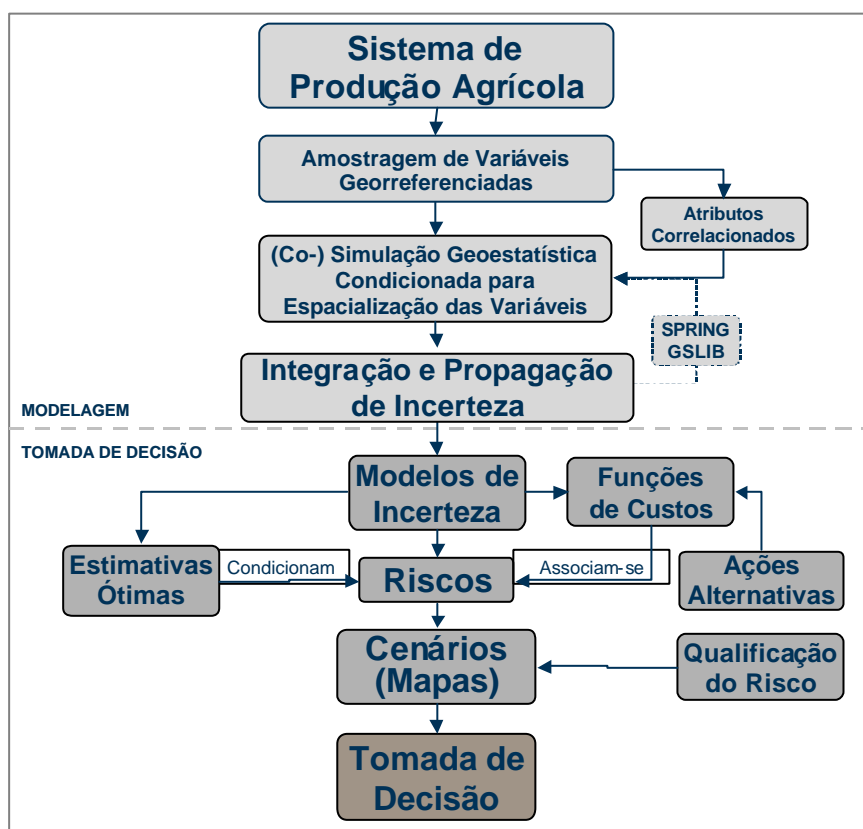


FIGURA 1.1 – Processo para tomada de decisão com base em modelagem espacial e construção de cenários de risco associados a funções de custo.

Partindo-se de um sistema agrícola, com nível tecnológico elevado já incorporado ao processo de produção, definem-se quais variáveis serão modeladas em função do problema a ser tratado. A modelagem espacial integra as variáveis definidas, através de procedimentos geoestatísticos, especificamente da simulação sequencial condicionada e método de Monte Carlo. Para esta Tese, o processo de modelagem requer avaliar e tratar a correlação entre as variáveis com variabilidade conjunta no espaço através da co-simulação.

No entanto, ao avaliar a correlação destas variáveis, o processo de modelagem requer uma simulação conjunta (co-simulação), para variáveis que variam conjuntamente no espaço.

A utilização de procedimentos geoestatísticos, segundo a abordagem por indicação (DEUTSCH e JOURNAL, 1998) permite gerar modelos de incerteza em cada localização do espaço amostrado. Estes modelos de incerteza se associam a funções de custo e às estimativas do modelo, de modo que os riscos podem ser definidos e associados às possíveis ações que o planejador pode tomar. Desta seqüência de procedimentos resultam os cenários para tomar decisões, composto pelos seguintes parâmetros: ações possíveis de intervenção, impactos ou cenários futuros, viabilidade econômica e riscos associados às alternativas propostas.

1.5 Prova de Conceito: O Caso do Sistema de Produção de Trigo em Carambeí, PR

Para testar a hipótese deste trabalho um experimento foi montado com base em um sistema de produção agrícola para o plantio de trigo, no município de Carambeí, no estado do Paraná. Este sistema de produção que foi implementado na Fazenda Figueira pela Empresa IMPAR (<http://www.imparag.com.br>), empresa de consultoria em inteligência de produção, que desenvolveu uma metodologia própria para o processo de planejamento. Observando os limites em sua proposta metodológica, a IMPAR forneceu então os dados, a situação de produção e o desejo do cliente para que a proposta metodológica pudesse ser testada em um domínio de produção agrícola realista e não simulado.

Muitos artigos na literatura relatam a acidez do solo como um dos fatores limitantes da produção de grãos, (QUAGGIO, 2004; CAÍRES, 2005 e NOLLA et al., 2005). O corretivo mais usado para corrigir a acidez nos solos brasileiros é o calcário. Porém, mesmo sendo de eficácia comprovada, a colocação deste insumo na lavoura depende, como outro qualquer, de uma decisão: colocar ou não o calcário e, ainda, aplicá-lo com um valor médio calculado em toda região ou estimar as reais necessidades do solo em cada região de plantio?

Um modelo matemático define a necessidade de calcário com base nos valores da acidez do solo obtidos através de amostragens. Neste experimento, visando tornar a proposta metodológica mais clara utiliza-se apenas uma variável do sistema de produção: a quantidade de calcário para controlar a acidez do solo, de modo a maximizar a produção e minimizar os custos, otimizando a lucratividade da área em questão.

No entanto, deve ficar claro que a metodologia proposta pode ser estendida a outros processos que envolvam modelagem espacial de dados, não havendo limite quanto ao número de variáveis envolvidas na modelagem, o que a torna flexível para tomadores de decisão com problemas geográficos semelhantes ao definido no estudo de caso

1.6 Organização deste Trabalho

Este trabalho se insere no contexto da linha de pesquisa e desenvolvimento da Divisão de Processamento de Imagens (DPI) do Instituto Nacional de Pesquisas Espaciais (INPE), que iniciou na década de 90, dentre outras atividades, pesquisas sistemáticas em novos procedimentos de tratamento, análise e modelagem de dados espaciais. Várias teses e dissertações têm sido geradas como resultado deste investimento, dentre os quais: Camargo (1997) – que trata da introdução de procedimentos geoestatísticos num ambiente computacional de geoprocessamento; Felgueiras (1999) – que estabelece a modelagem ambiental com tratamento de incertezas sob o paradigma geoestatístico por indicação, Bönisch (2001) – que apresenta uma metodologia para geoprocessamento ambiental com tratamento de incerteza, e aplica para o caso do zoneamento pedoclimático para a soja no estado de Santa Catarina e Ortiz et al. (2004), sobre

modelagem de fertilidade do solo por simulação estocástica com tratamento de incertezas. O trabalho mais recente nesta linha de pesquisa é o de Camargo et al. (2008), que aborda a distribuição espacial do risco, porém associada a eventos raros (homicídios, por exemplo) e onde o tratamento proposto é a abordagem da geoestatística binomial.

Esta Tese dá continuidade à linha de pesquisa apresentada, sob o enfoque da modelagem espacial de dados e a representação espacial do risco seguindo o enfoque da geoestatística não linear, ou por indicação. Está organizado em cinco capítulos. No primeiro é apresentada uma revisão teórica sobre o que envolve o problema em estudo, como forma de contextualizar o leitor em termos modelagem espacial em SIG e tomada de decisão. No segundo capítulo são apresentadas as bases de fundamentação teórica dos procedimentos geoestatísticos adotados para a modelagem de incerteza. Apresenta, também, o conceito de risco adotado neste trabalho e alguns trabalhos correlatos que abordam o tema. O terceiro capítulo apresenta a proposta metodológica desta Tese e mostra como integrar procedimentos geoestatísticos com funções de custo para definição de parâmetros de planejamento. O quarto capítulo trata do experimento montado para avaliar a metodologia, onde é apresentado o problema e o modelo adotado, e a metodologia proposta é exercitada para a área de estudo e analisada. Para finalizar, o quinto capítulo apresenta uma discussão com base nos resultados do experimento proposto estabelecendo um conjunto de conclusões e realçando as contribuições deste trabalho.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA INCERTEZA, RISCO E TOMADA DE DECISÃO

2.1 Introdução

Um dos fatores importantes a considerar em uma tomada de decisão racional é a incerteza. A maior parte das decisões é tomada seguindo algum tipo de previsão, o que, por si só, já coloca o fator incerteza no processo de decisão. As incertezas podem ser provenientes de informação incompleta, ou mesmo por haver discordância entre as fontes de informação. Mesmo diante de uma informação considerada completa, as incertezas podem surgir devido às simplificações ou aproximações adotadas, quando modelos matemáticos são utilizados para representar um problema, por exemplo.

Uma definição apresentada por Harris (1998), diz que tomar uma decisão é o processo de reduzir suficientemente a incerteza sobre as alternativas disponíveis para fazer a escolha mais adequada possível. Nesta definição, a incerteza é reduzida e não eliminada. Como poucas situações conduzem a certeza absoluta, devido à informação incompleta sobre todas as alternativas possíveis, toda decisão envolve risco.

O que normalmente ocorre, principalmente em problemas que envolvem estimativas de uma grandeza ou atributo relacionado a fenômenos ambientais, por exemplo, propriedades químicas do solo, é a insuficiência de informações ou observações, limitada à amostragem esparsa. Desta forma, considera-se que um fator importante no processo de tomar uma decisão é avaliar o grau de incerteza existente no processo de decisão e buscar uma estimativa do risco envolvido.

O risco é definido em Andrade (2000), como uma estimativa do grau de incerteza que se tem com respeito à obtenção de resultados desejados.

Bernstein (1997), em seu livro, *Desafio aos deuses: a fascinante história do risco*, descreve que há poucas décadas o risco começou a ser estudado de forma sistemática,

com o objetivo de ser entendido, quantificado e administrado nas mais variadas situações, convertendo o futuro incerto, de ameaça, em oportunidade. O autor afirma que a idéia revolucionária que define a fronteira entre os tempos modernos e o passado é o domínio do *risco*: a noção de que o futuro é mais do que um capricho dos deuses e de que homens e mulheres não são passíveis ante a natureza é enfatizada no livro. Até os seres humanos conseguirem transpor esta fronteira, o futuro era apenas um espelho do passado ou pertencia ao domínio obscuro de oráculos e adivinhos que detinham o monopólio sobre o conhecimento.

Uma visão mais científica e aprofundada sobre o processo decisório é apresentada por Bazerman, (2002) e Rafaelli, (2004). E envolve três etapas consideradas fundamentais: inteligência, projeto e escolha. Na etapa de inteligência o decisor busca aprofundar conhecimentos sobre o problema, analisando seus componentes, propriedades e inter-relacionamentos. Trata-se de uma etapa investigativa. A fase do projeto caracteriza-se pela busca da solução e muitas vezes um modelo matemático do sistema³ constitui uma ferramenta útil. Esses modelos matemáticos ajudam a estimar as conseqüências da decisão, ao resultar em cenários. Os cenários, neste sentido, apresentam visualmente o resultado de um processo de modelagem que envolve as variáveis de interesse e que contribuem para a formulação de alternativas de ação.

A decisão, no entanto, é tomada na etapa da escolha e, em geral, o decisor assume riscos quanto às conseqüências de uma determinada decisão. O conceito de risco, conforme abordado anteriormente está associado à probabilidade de ocorrências desfavoráveis, decorrentes das ações tomadas, a partir da informação utilizada. Tomar uma decisão é, portanto, um processo onde o elemento risco desempenha um papel importante na avaliação de cenários que representam mais de uma diretriz de ação. Assim, as ações que vão resultar do planejamento devem estar bem alicerçadas em um conjunto de informações que disponha de modelos de risco associados.

³ Sistema: um conjunto de componentes que interagem para um determinado fim (RAFAELLI, 2004).

2.1.1 Informação Espacial e o Planejamento na Tomada de Decisão

Os conceitos de dados geográficos, informação e tomada de decisão encontram-se inter-relacionados. Quando dados espaciais são organizados, apresentados, analisados, e interpretados passam a serem considerados úteis para um problema de decisão específico, transformam-se em informação espacial. Assim, os problemas que envolvem dados espaciais e informação espacial são designados por problemas de decisão espacial (MALCZEWSKI, 1999).

Devido a sua natureza geográfica, os problemas que envolvem decisão espacial têm sido conduzidos através de procedimentos de geoprocessamento (AERTS et al., 2003 & PEARLSTINE e MAZZOTTI, 2004). De acordo com Krivoruchko e Crawford (2003), uma operação de geoprocessamento consiste de um ou mais algoritmos que geram novos dados espaciais a partir de um conjunto de amostras georeferenciadas. Muitos destes algoritmos envolvem estimativas de novos dados, produzindo informação, por exemplo, derivada de modelos matemáticos desenvolvidos em ambiente computacional. Em geral, as estimativas resultantes apresentam a componente de incerteza, inerente a todo processo de construção da informação.

Muitos exemplos na literatura apresentam a importância da incerteza resultante de operações de geoprocessamento como em Heuvelink (1998), Bonisch (2001), Zhang e Goodchild (2002), Krivoruchko e Crawford (2003). apresentam exemplos que demonstram que análises espaciais sofisticadas não podem atingir seus objetivos usando unicamente métodos determinísticos de geoprocessamento. Os autores denominam geoprocessamento probabilístico, os métodos que fazem uso de distribuições de probabilidade nas análises de geoprocessamento. Dentre as possibilidades de uso do geoprocessamento inclui-se a geoestatística.

O próximo item apresenta a questão da informação espacial no planejamento de um ramo específico da agricultura, denominado agricultura de precisão.

2.1.2 Informação Espacial e Agricultura de Precisão

*“O rápido desenvolvimento da tecnologia e a redução do custo dos equipamentos têm auxiliado a coleta, o armazenamento e o processamento de dados e informações de maneira mais eficiente, nos mais variados processos produtivos, incluindo o agrícola. Assim, a **informação** passa a ser valiosa e deve ser considerada como mais um **insumo** no **processo produtivo**. A informática representa, dessa maneira, um auxílio à agricultura, reduzindo os custos dessa informação.” (PAGLIS, 2002).*

Este item trata da informação espacial e do seu vínculo com o planejamento agrícola, em especial, em agricultura de precisão, pois, o experimento deste trabalho envolve estes temas.

A necessidade por informação de qualidade, como subsídio aos processos de planejamento agrícola, tem se apoiado na tecnologia da informação (MARTIN et al, 1998). Os ambientes computacionais de geoprocessamento, materializados pelos SIG, acrescentam um diferencial na construção da informação espacial que é utilizada neste tipo de planejamento. A agricultura de precisão é um dos potenciais usuários dessa informação espacial e foi definida por Manzatto et al. (1999), como: “o uso racional de tecnologias atuais para o manejo do solo, insumos e culturas, de modo adequado às variações espaciais e temporais dos fatores que afetam a produção agrícola”.

De acordo Lamparelli e Rocha (1997), o conceito de agricultura de precisão leva em conta as características espaciais das variáveis consideradas no processo de produção, sob o enfoque de uma utilização racional do solo que conduza a um aprimoramento da produtividade com redução dos impactos ambientais, aliada a uma minimização de custos, e, para isso, as práticas agrícolas têm de ser repensadas.

Em agricultura de precisão é necessário estar ciente das variações espaciais que ocorrem dentro da propriedade, principalmente dentro de um mesmo talhão. Muitas vezes, visualmente no local, essas variações são imperceptíveis. Caracteriza-se, assim, a

necessidade de ferramentas adequadas, que representem essas variações, permitindo tomar decisões conscientes e fundamentadas.

A implementação de novos métodos na agricultura depende, contudo, da percepção, por parte do produtor, de como a adoção de novos conceitos e técnicas, pode aumentar a produtividade e o lucro e tornar menor o seu risco na produção.

O trabalho apresentado por Manzatto et al. (1999), mostrou que o aumento na produção agrícola tem sido obtido com a utilização de grandes quantidades de insumos químicos. Atualmente, as empresas se utilizam de adubações, mas que nem sempre são eficientes para todos os tipos de solo e para todas as culturas agrícolas. Esta heterogeneidade pode ocasionar regiões onde a exigência nutricional do cultivo não é atendida e regiões onde ocorra o excesso de adubação e a conseqüente lixiviação das sobras, havendo o desperdício de recursos. O controle desse desperdício e adequação de insumos no solo, frente ao meio ambiente, é um dos principais objetivos da agricultura de precisão.

Confirmando o avanço da agricultura de precisão no cenário econômico e ambiental, o trabalho desenvolvido pela empresa IMPAR no monitoramento e controle de várias fazendas que adotam essa prática, vem demonstrando que ao contrário do conceito convencional da aplicação de insumos pela média, onde extensas áreas são gerenciadas de forma idêntica, como um sistema uniforme, a Aplicação à Taxa Variável (ATV) também denominada de "Variable Rate Technology" (VRT) diminui os riscos de contaminação ambiental. Estes riscos são causados pela aplicação de alguns nutrientes em doses acima da necessária, e pela ineficiência do insumo devido à aplicação de doses abaixo das reais necessidades de cada local.

Tem sido demonstrado através de artigos como em Manzatto (1999) e Searcy (2000), que essa técnica pode reduzir os custos de produção, com a economia de insumos aplicados, provocada pela otimização na utilização dos mesmos, mantendo ou melhorando o nível de produção e acarretando ganho de produção e maximização dos lucros.

Por outro lado a modelagem geoestatística vem sendo empregada em agricultura de precisão, principalmente para avaliar a variabilidade espacial de atributos do solo (VETTORAZZI e FERRAZ, 2000 & ORTIZ, 2003). Os autores, Dainese et al. (2003), geraram representações contínuas de atributos do solo, em termos de índices de produtividade ou dados de fertilidade. A modelagem geoestatística também tem sido utilizada em trabalhos que consideram a propagação de incertezas. Esses trabalhos (VISCARRA ROSSEL et al., 2001 e BÖNISCH, 2001), voltados a mapeamentos com dados agrícolas, enfatizam a qualidade da informação gerada por SIG.

No entanto, a tecnologia de SIG requer que novos procedimentos estocásticos sejam incorporados a esses sistemas, ampliando a sua capacidade, no sentido de auxiliarem as tomadas de decisões nos problemas que envolvem a componente espacial da informação. É nesse contexto que está inserida a proposta deste trabalho e que a partir do item seguinte apresenta a formalização da geoestatística para auxiliar as atividades de planejamento e tomada de decisão.

2.2 Abordagem Geoestatística

Estudos exploratórios e qualitativos, que envolvem as atividades humanas e os processos físicos e químicos que ocorrem na natureza, são importantes para entender os diversos problemas ambientais que vêm ocorrendo nas últimas décadas. No entanto, segundo Myers (1997), há que se considerar, também, que as ações para detectar, monitorar, avaliar e conseqüente tomar decisão em um determinado problema, estão baseadas na quantificação da informação disponível e nas incertezas envolvidas. Esse fato gera a necessidade de desenvolver procedimentos que proporcionem avaliações confiáveis, incluindo a quantificação das incertezas inerentes ao próprio processo de decisão. Wilmot (2003) apresentou um relatório que descreve como o conceito de probabilidade pode ser utilizado como um meio de expressar a incerteza.

A propagação de incertezas nos atributos espaciais manipulados em SIG tem sido abordada na literatura por meio de procedimentos geoestatísticos, incluindo a simulação (HEUVELINK, 1998 & AGUMYA e HUNTER, 2002).

Nos modelos geoestatísticos, os dados amostrados são interpretados como provenientes de um processo aleatório. O fenômeno que está ocorrendo no espaço geográfico, como formações geológicas por onde circulam fluídos petroquímicos importantes, aquíferos contaminados ou a concentração de poluentes etc, em geral, apresenta informação disponível (amostras ou observações) parcelada e, normalmente, escassa. Aqui dois fatores são levantados: para conhecimento global do fenômeno é necessário dispor de modelos que permitam inferir as grandezas ou atributos desses fenômenos espaciais, nos locais não amostrados, a partir da informação disponível; e esse conhecimento global está associado à incerteza, proveniente, principalmente da falta de conhecimento que se tem em relação ao fenômeno.

O fundamento teórico da geoestatística foi desenvolvido por Matheron (1971), e está baseado na associação do conceito de variável regionalizada com o modelo de probabilidades. De forma resumida, a variável regionalizada é uma variável distribuída no espaço e ou no tempo, e seus valores são considerados como realizações de uma função aleatória ou campo aleatório (WACKERNAGEL, 1998). Essa teoria permite estabelecer um modelo probabilístico inferencial adequado ao fenômeno a ser estudado, de modo que, em cada posição do espaço \mathbf{u} , o valor do atributo, z^4 , é considerado uma realização da variável aleatória (VA), $Z(\mathbf{u})$.

A geoestatística interpreta um valor localizado espacialmente em \mathbf{u} , denominação genérica adotada para representar um conjunto de coordenadas geográficas, como uma realização $z(\mathbf{u})$ da variável aleatória (VA) $Z(\mathbf{u})$. No espaço A, onde está localizado o conjunto de amostras, N realizações das VA $Z(\mathbf{u}_1), Z(\mathbf{u}_2), \dots, Z(\mathbf{u}_N)$, correlacionadas entre si, estão disponíveis.

O conjunto de VA $Z(\mathbf{u}_i)$, $i=1, \dots, N$, correlacionadas entre si, constituem uma função aleatória (FA), da qual só se conhece uma realização $z(\mathbf{u}_i)$, ou seja, o conjunto de dados amostrados.

⁴ A conotação de z , em letra minúscula, reflete, neste trabalho, realizações da VA Z , que está sempre representada por letra maiúscula.

No entanto, com uma só realização de cada VA é teoricamente impossível de determinar qualquer parâmetro estatístico das variáveis individuais ou da função. Assim, a solução proposta pelo formalismo da geoestatística consiste em assumir diversos graus de estacionariedade da FA, para que a inferência de alguns parâmetros estatísticos se torne possível. Esta teoria foi proposta por Matheron (1978) e ao admitir que todas as VA têm a mesma média, como definida na expressão 2.1, este parâmetro passa a ser independente da localização u_i . A média pode, então, ser estimada como a média aritmética dos valores das realizações das VA:

$$E\{Z(u_1)\} = E\{Z(u_2)\} = \dots E\{Z(u_i)\} = E\{Z(u)\} = m \quad e$$

$$m = \frac{1}{N} \sum_{i=1}^N Z(u_i) \quad (2.1)$$

Esta hipótese de estacionariedade da média, ou primeiro momento estatístico, é parte integrante e fundamental do modelo probabilista geoestatístico. Contudo, ela pode ser julgada apropriada ou não, dependendo da homogeneidade das amostras em A. Julgar a hipótese da estacionariedade da média das amostras como apropriada e representativa de A, é considerar que os valores das amostras são suficientemente homogêneos para validar tal representatividade (CAMARGO, 1997 e SOARES, 2000).

Para medir a correlação entre duas VA utiliza-se ou a covariância ou a variância, também denominadas de segundo momento estatístico. A hipótese de estacionariedade destes parâmetros é definida em Camargo (1997), como: a correlação entre duas VA depende somente da distância espacial que as separa e é independente da sua localização. Ou seja, a correlação entre duas VA quaisquer, distanciadas espacialmente de um vetor h , depende somente de h e $h = u_1, u_2 = u_i, u_i+h$.

Assim como para a média, a estacionariedade do segundo momento permite inferir o variograma⁵ e a covariância, levando-se em consideração as N amostras $Z(u_i)$, $i=1, \dots, N$.

⁵ Variograma é por definição a variância entre $(Z(u)-Z(u+h))$, quando ambos os pontos, u e $u+h$, pertencem à área A (DEUTSCH e JOURNAL, 1989).

De modo resumido, segundo Journel (1989), pode-se dizer que a média e a variância ou a covariância, juntamente com as hipóteses de estacionariedade dos mesmos, são fundamentais na definição dos modelos geoestatísticos:

- Os valores das amostras são realizações de VA localizadas espacialmente em A, $Z(\mathbf{u}_i)$, $i=1, \dots, N$, cuja correlação medida pela covariância ou variograma, depende apenas do vetor \mathbf{h} e não da localização da VA. O variograma mede a continuidade espacial ou a dispersão das variáveis que caracterizam um fenômeno espacial.
- Um valor não amostral $Z(\mathbf{u}_0)$ é também considerado uma VA localizada em \mathbf{u}_0 e o estimador⁶ deste valor, é uma combinação linear de outras VA (Equação 2.2):

$$- Z^*(\mathbf{u}_0) = \sum_{i=1}^N \lambda_i Z(\mathbf{u}_i) \quad (2.2)$$

- Onde λ são os ponderadores definidos pelo formalismo geoestatístico (CAMARGO, 1997; GOOVAERTS, 1997 e FELGUEIRAS, 1999), e que seguem dois critérios: o não enviesamento e a variância de estimativa mínima.
- Uma vez caracterizados os parâmetros estatísticos da FA, pode-se gerar ou simular outras N_s realizações da mesma função $Z_{s,j}(\mathbf{u})$, $j = 1, \dots, N_s$, com a mesma média, variograma e função de distribuição de $Z(\mathbf{u})$.

O estimador geoestatístico é denominado Krigeagem, uma denominação em homenagem aos trabalhos pioneiros do engenheiro de minas D. Krige. A krigeagem ordinária é o algoritmo mais usual da família de estimadores geoestatísticos (krigeagem simples, krigeagem com modelo de deriva, ou universal, krigeagem com deriva externa) a cokrigeagem que é usada para situações onde há uma segunda VA auxiliar na estimativa, os estimadores não lineares, a krigeagem por indicação e a multigaussiana. Todos estes estimadores encontram-se documentados em vasta literatura sobre o

⁶ O valor estimado é, neste texto, indicado pelo símbolo (*).

assunto, dentre eles: Goovaerts (1997); Deutsch e Journel (1998); Wackernagel (1998); Isaaks e Srivastawa (1989) & Felgueiras (1999).

Este item apresentou uma visão geral sobre a modelagem geoestatística e, em seguida, apresenta como os estimadores geoestatísticos podem ser utilizados no tratamento de incertezas e riscos.

2.2.1 Inferência Espacial e a Incerteza da Informação Espacial

A incerteza em dados geográficos tem sido colocada em foco por diversos pesquisadores devido às conseqüências adversas que podem ocorrer em tomadas de decisão que consideram estes dados. Este tema foi abordado por Agumya e Hunter (2002), que relatam que a qualidade de uma decisão pode ser avaliada de acordo com a sua utilidade. Essa utilidade pode ser definida em como uma função de incertezas, riscos, custos e benefícios. Para a qualidade de uma decisão ser aceitável, o risco associado à decisão também deve ser aceitável, e uma das ferramentas mais importantes no gerenciamento de riscos é a informação utilizada. O nível de aceitabilidade deve ser discutido pelos usuários da informação.

A abordagem deste estudo visa adotar os SIG para auxiliar as decisões. No entanto, ao utilizar um SIG para manipular dados geográficos, segundo Goodchild (2001), o administrador de riscos ou o tomador de decisões necessita conhecer diferentes aspectos de um mapeamento obtido por operações de SIG. O seu objetivo não é simplesmente navegar no espaço físico (onde estão os riscos?), mas também navegar no espaço da decisão (O que pode ser feito para efetivamente reduzir estes riscos?). Para tais respostas, o conhecimento da incerteza na informação e sua propagação são essenciais.

A questão da propagação de incertezas, quando a informação é gerada em ambiente de geoprocessamento, foi abordada por Heuvelink (1998). O autor relata em seu trabalho que uma das grandes capacidades de um SIG, particularmente em ciências ambientais, é a possibilidade de derivar novos atributos, a partir de atributos já incorporados em um banco de dados. Quando mapas são armazenados em um SIG e são usados como dados de entrada para qualquer operação de manipulação, as incertezas desses dados se

propagam para o resultado final da operação. Quando não há registro algum sobre a precisão dos resultados intermediários torna-se complexo avaliar a precisão do resultado final.

Os problemas que envolvem a informação espacial e conseqüente tomada de decisão foram relatados por Malczewski (1999), que os definiu como problemas de decisão espacial. Esses problemas, em geral, admitem mais de uma alternativa de decisão, cujas conseqüências diferem no espaço. Cada alternativa é avaliada com base em critérios diferentes, que podem ser qualitativos e/ou quantitativos. Cada decisão envolve, na maior parte dos casos, um ou mais fatores de incerteza. Assim, uma boa escolha para tomada de decisão depende amplamente da quantidade e da qualidade da informação disponível para os tomadores de decisão.

A quantificação de parâmetros de incerteza, portanto, torna-se fundamental em análises de produtos de SIG que envolvam a posterior propagação de incertezas e análise de riscos no processo de modelagem computacional. Eastman et al. (1997), propuseram a exploração de metodologias que ilustrem a contribuição do geoprocessamento em todas as fases do processo de gerenciamento de riscos ambientais, de modo a tornar as decisões mais qualificadas. Os autores sugeriram que métodos mais robustos que permitam a quantificar a variância como medida de incerteza, por exemplo, deveriam ser integrados à tecnologia de SIG. Tal consideração tem avançado significativamente nos SIG atuais, como por exemplo, o SPRING (<http://www.dpi.inpe.br/spring>), IDRISI Decision Support (<http://www.sbg.ac.at/geo/idrisi/specdeci.htm>) e ArcGIS (<http://www.esri.com>).

Uma abordagem com crescente aceitação para avaliação de incerteza e risco inclui os procedimentos inferenciais geoestatísticos de krigeagem e simulação estocástica. Estes procedimentos fazem uso de um conjunto de amostras pontuais e do modelo de correlação para estimar valores de um atributo em posições não amostradas. A abordagem geoestatística apresenta dois métodos para estimar a incerteza de um atributo no espaço não amostrado: o formalismo por indicação e o multigaussiano. Estes procedimentos serão abordados no item 2.2.2.

Ambos procedimentos permitem modelar incerteza ligada ao atributo ou grandeza em estudo, em um dado ponto u_0 : especificamente, a probabilidade do valor no local u_0 exceder ou ser menor que um dado valor de corte, ou a probabilidade do valor no local u_0 estar contido entre dois quantis, por exemplo, (FELGUEIRAS, 1999 e SOARES, 2000). Não se trata, nestes casos, de ter acesso ao valor médio da variável $Z(u)$, mas da função de distribuição de probabilidade que a descreve como VA.

Vários autores na literatura, Goovaerts (1997), Soares (2000), Bönisch (2001), Saito e Goodchild (2001), Goovaerts (2001), Aerts et al. (2003), Ortiz et al. (2004), têm apresentado a contribuição da teoria geoestatística. A abordagem da geoestatística mostra-se adequada sob vários aspectos: nos procedimentos de espacialização de atributos, como estimadores de mínima variância; na possibilidade de complementar os dados amostrados, por vezes, escassos, com amostras indiretas correlacionadas (BOURENNANE e COTURIER, 2000 & GOOVAERTS e VAN MERVEINE, 2001), na modelagem de incertezas e na avaliação de riscos.

2.2.2 Incerteza – Enfoque Paramétrico e Não Paramétrico

As aplicações dos procedimentos da geoestatística nos mapeamentos direcionados ao planejamento, em geral planejamento ambiental, vêm colocando em foco a importância da representação da incerteza, conforme alguns trabalhos: Goovaerts (2001); Narula et al. (2002) & Lark e Ferguson (2004). As informações espaciais, ou espaço-temporais, fornecidas ao planejador, em decorrência da restrição de dados observados, fazem com que as decisões sejam efetuadas considerando os diferentes níveis de incerteza dessa informação, através dos procedimentos inferenciais.

A abordagem da geoestatística não linear considera as distribuições de probabilidades locais para modelar a incerteza da VA. De acordo com Felgueiras (1999), nesse caso, primeiro é necessário inferir as distribuições de probabilidades locais em cada ponto do espaço a ser estudado. Essas distribuições são caracterizadas pela função de distribuição acumulada condicionada, $F(u; z|n)$. O termo, condicionada, refere-se aos n dados amostrados, $F(u; z|n)$, e modelam a incerteza da VA Z , no local u .

Nesse caso, a modelagem de incerteza pode ser efetuada por dois tipos de procedimentos que são a krigeagem não linear, para o cálculo das distribuições univariadas e as simulações sequenciais, para as distribuições de probabilidades multivariadas (GOOVAERTS, 1997).

Os modelos das fdac podem ser inferidos, em cada ponto do espaço, considerando os seguintes formalismos: a abordagem paramétrica (em geral, a multigaussiana) ou a abordagem não paramétrica, também denominada por indicação. Uma vez calculado o modelo da função de distribuição de probabilidades $F_z(z, \mathbf{u})$ para o conjunto de pontos \mathbf{u} da área de estudo A , pode-se inferir valores relativos à incerteza das estimativas. Uma outra abordagem paramétrica foi definida por Diggle et al. (2003), com o termo “model based geostatistics” e que implica a aplicação de modelos paramétricos e métodos baseados em probabilidades de inferência. No entanto, não é escopo deste trabalho tratar desse enfoque geoestatístico.

A seguir, a abordagem paramétrica e não paramétrica pra determinar as fdac serão apresentadas.

2.2.2.1 Enfoque Paramétrico – Multigaussiano

Um dos meios para derivar uma fdac local consiste em supor um único modelo conhecido para a função de distribuição do conjunto de variáveis aleatórias (GOOVAERTS, 1997; DEUTSCH e JOURNAL; 1998 & SOARES, 2000). Um exemplo, deste tipo de modelo é o multigaussiano. Segundo e Deutsch e Journal (1998) & Atkinson (1999), sob a hipótese de multigaussianidade, a função de distribuição de probabilidade em um ponto \mathbf{u}_0 qualquer, fica definida com base nos dois parâmetros estimados por krigeagem simples, a média e a variância. Desse modo, fica estabelecido um modelo de distribuição a priori.

2.2.2.2 Enfoque Não Paramétrico - Por Indicação

Essa abordagem utiliza-se do formalismo não paramétrico, denominado, por indicação. Neste caso, a variável $Z(\mathbf{u})$ é transformada em uma variável por indicação, $I_Z(\mathbf{u})$.

Na distribuição de um conjunto de dados amostrais, um determinado número de cortes K e seus valores de corte $z_k, k=1, \dots, K$, são definidos. Os K valores de corte são definidos em função do número de amostras e devem ser escolhidos de forma que os $K+1$ cortes contenham aproximadamente as mesmas frequências. Em geral, os valores de corte são definidos utilizando os quantis.

A codificação por indicação se processa para cada valor de corte z_k , e gera um conjunto amostral por indicação $i(\mathbf{u}, z_k)$, do tipo definido na equação (2.3), (GOOVAERTS, 1997; SRIVASTAWA, 1989 e DRUCK et al. 2002). Ao aplicar a codificação por indicação sobre todo o conjunto amostral, para cada valor de corte, gera-se um conjunto cujos valores são 0 (zero) ou 1 (um).

$$i(\mathbf{u}, z_k) = \begin{cases} 1, & \text{se } z(\mathbf{u}) \leq z_k \\ 0, & \text{se } z(\mathbf{u}) > z_k \end{cases} \quad (2.3)$$

Ao utilizar um estimador de krigeagem por indicação, por exemplo a krigeagem por indicação simples, o procedimento de krigeagem linear simples é aplicado ao conjunto amostral codificado por indicação em $z = z_k$, fornecendo para cada valor de corte k , uma estimativa que é também a melhor estimativa mínima quadrática da esperança condicional da VA $I(\mathbf{u}; z_k)$. Utilizando esta propriedade, as estimativas dos valores da fdac de $Z(\mathbf{u})$ para vários valores de z_k , podem ser calculadas. O conjunto dos valores estimados das fdac de $Z(\mathbf{u})$, nos valores de corte, é considerado uma aproximação discretizada da fdac real de $Z(\mathbf{u})$. Quanto maior a quantidade de valores de corte melhor é a aproximação (FELGUEIRAS, 1999). Este procedimento é apresentado no Apêndice A.

A estimativa de krigeagem de uma variável por indicação $I_z(\mathbf{u})$, é também uma estimativa de sua esperança condicional. Portanto, as estimativas de $F_z^*(z; \mathbf{u})$, para $k=1, \dots, K$, podem ser calculadas obtendo-se o valor $i^*(z, \mathbf{u})$, que utiliza para sua estimativa os dados transformados para dados por indicação, com valores 1 e 0. Os procedimentos por indicação iniciam-se por uma transformação não linear, denominada

codificação por indicação, que transforma cada valor do conjunto amostral, $z(\mathbf{u})$, em valores por indicação, $i(z, \mathbf{u})$, (GOOVAERTS, 1997).

A esperança do conjunto estacionário das variáveis $I_z(\mathbf{u})$ fica igual à probabilidade de ocorrer um valor de $Z(\mathbf{u})$ inferior a z , definida em Deutsch e Journel (1998) como :

$$E\{I_z(\mathbf{u})\} = \text{prob}\{Z(\mathbf{u}) < z\}^* = m_I(z) \quad (2.4)$$

Assim, $F_z(z; \mathbf{u})$ pode ser descrita em função de $I_z(\mathbf{u})$:

$$F_z(z; \mathbf{u}) = \text{prob}\{Z(\mathbf{u}) < z\} = E\{I_z(\mathbf{u})\} \quad (2.5)$$

A idéia é estimar diretamente $F_z(z, \mathbf{u})$, através da variável por indicação $I_z(\mathbf{u})$:

$$F_z(z; \mathbf{u})^* = \text{prob}\{Z(\mathbf{u}) < z\}^* = [I_z(\mathbf{u})]^* \quad (2.6)$$

O gerenciamento de alguns recursos naturais, por vezes, exige o conhecimento, não só das suas características médias, conforme o fazem o estimador de krigagem simples ou ordinária, apresentado em Goovaerts (1997) & Deutsch e Journel (1998), mas também, das suas características extremas. Por exemplo, a fração do recurso que permanece acima de um dado valor (valor de corte, z_c) ou de um parâmetro de qualidade.

Um exemplo prático deste tipo de aplicação, na fase de reconhecimento de um aquífero, por exemplo, inclui conhecer os valores médios de permeabilidade das formações geológicas. Porém, segundo Soares (2000), para a posterior gestão da qualidade das reservas de água, é fundamental o conhecimento da localização espacial dos valores extremos de permeabilidade. Estes valores é que condicionam, por formarem barreiras ou caminhos preferenciais, o escoamento do fluído. Assim também ocorre em estudos de impacto ambiental de um poluente atmosférico ou do solo. Nestes casos, para quantificação do poluente é necessário o conhecimento da dispersão espacial dos valores extremos desse poluente.

A krigagem por indicação por não ser paramétrica não se restringe à modelagem de atributos com distribuições simétricas, como, por exemplo, a distribuição gaussiana. Possibilita a construção de uma aproximação discretizada da fdac de $Z(\mathbf{u})$, podendo ser

usada diretamente para estimar valores característicos da distribuição, permitindo a estimativa de incertezas para atributos espaciais de natureza temática e numérica. Este trabalho, porém, trata apenas de atributos de natureza numérica.

2.2.3 Medidas de Incerteza Local

A partir da aproximação discretizada da fdac de $Z(\mathbf{u})$, seja com o formalismo paramétrico ou não paramétrico, os valores de probabilidades discretizados podem ser usados diretamente para estimar valores característicos da distribuição, tais como: valor médio, variância, moda, quantis e outros. Esses valores podem ser associados à representação da incerteza dos valores estimados.

O trabalho de Felgueiras (1999), apresenta a teoria dos métodos geoestatísticos para modelagem e propagação de incertezas, usando os conceitos estabelecidos, principalmente, em Goovaerts (1997), Deutsch e Journel (1998) & Heuvelink (1998). O objetivo principal do trabalho foi sistematizar uma metodologia para modelagem ambiental em SIG, sob o paradigma geoestatístico por indicação, considerando a informação de incerteza. Foram especificados os requisitos para integrar procedimentos de inferência e métricas de incerteza no ambiente de SIG. O autor aborda a importância de se considerar o tratamento de incertezas das representações dos dados espaciais envolvidos em modelagem espacial em SIG.

De modo resumido, a incerteza local, em uma posição não amostrada, \mathbf{u} , a partir da fdac, pode ser modelada para atributos numéricos, segundo Felgueiras (1999), de dois modos:

- *Intervalo de Confiança*⁷: que consiste em computar: a estimativa de mínima variância do erro, através da krigagem, ou seja, $z^*(\mathbf{u})$, do valor desconhecido, $z(\mathbf{u})$ e, a variância do erro associada. A estimativa e o erro da variância (γ) são, então, combinados para derivar um intervalo de confiança do tipo gaussiano, que pode ser centrado no valor médio estimado $\mathbf{m}_z(\mathbf{u})$. Isso ocorre quando se pode

⁷ Intervalo de confiança descreve um intervalo no qual um valor estimado, por exemplo, a média, estará incluída com um nível específico de certeza, por ex. 90% (MYERS, 1997).

supor a hipótese de normalidade para a distribuição (simétrica), por exemplo, um intervalo de 95% de confiança:

$$\Pr ob\{Z(\mathbf{u}) \in [\mathbf{m}_z(\mathbf{u}) - 2\mathbf{s}(\mathbf{u}), \mathbf{m}_z(\mathbf{u}) + 2\mathbf{s}(\mathbf{u})]\} = 0.95 \quad (2.7)$$

Onde, $\mathbf{s}^2 = E\{(Z(\mathbf{u}) - E\{Z(\mathbf{u})\})^2\}$ é a variância da distribuição.

Para distribuições muito assimétricas, ao invés do intervalo centrado na média, pode-se usar o *intervalo interquartil*. Esse intervalo é definido como a diferença entre dois quantis, simétricos em relação à mediana. Por exemplo, o intervalo de 95%, $[q_{0.025}; q_{0.975}]$, tal que, $q_{0.025}$ é o quantil 0.025 e $q_{0.975}$ é o quantil 0.975 da fdac da VA, de modo que o intervalo de 95% é expresso em (2.8) como:

$$\Pr ob\{Z(\mathbf{u}) \in [q_{0.025}; q_{0.975}] | (n)\} = 0.95 \quad (2.8)$$

- *Intervalo de Probabilidade*: considera que a probabilidade de um valor $z(\mathbf{u})$ esta dentro de um intervalo $[a,b]$ qualquer, a partir da diferença entre os valores da fdac, para os limiares b e a , conforme em (2.9):

$$\Pr ob\{Z(\mathbf{u}) \in (a,b) | (n)\} = F(\mathbf{u};b | (n)) - F(\mathbf{u};a | (n)) \quad (2.9)$$

Um intervalo de 70% significa que existe 70% de probabilidade do intervalo conter o valor $z(\mathbf{u})$ e, portanto, 30% de estar fora do intervalo $(a,b]$. Estas probabilidades mostram-se particularmente importantes em aplicações ambientais que visam estabelecer o risco de se exceder limites regulatórios.

De maneira análoga, a incerteza pode ser estimada para atributos temáticos. Apenas para exemplificar, um tipo de cálculo dessa incerteza pode ser obtido através da moda da distribuição. A incerteza em \mathbf{u} , $Inc(\mathbf{u})$, pode ser determinada por um único valor de probabilidade, a probabilidade da classe s_k , que foi associada à posição \mathbf{u} , como mostrado em (2.10):

$$Inc(\mathbf{u}) = 1 - p_k(\mathbf{u}) \quad (2.10)$$

onde, $p_k(\mathbf{u}) = \Pr ob\{Z(\mathbf{u}) = s_k\}$.

2.2.4 Medidas de Incerteza Espacial - Simulação

No item anterior a estimativa da incerteza de um atributo em um local não amostrado foi apresentada sob os formalismos por indicação e multigaussiano. Nestes casos, a incerteza é fornecida através do histograma local estimado, em um dado ponto u_0 . Obtém-se a probabilidade do valor naquele ponto exceder ou ser menor ou igual a um dado valor de corte, ou ainda, a probabilidade do valor em u_0 , estar contido entre dois quantis, por exemplo.

No entanto, há situações em que o interesse na avaliação da incerteza não se resume a um único ponto ou a uma área específica, mas a um conjunto de pontos, simultaneamente. Ou seja, deseja-se saber a probabilidade de um conjunto de pontos exceder, simultaneamente, um dado valor limite. Essa incerteza é denominada incerteza espacial ou global e para avaliá-la existem os modelos geoestatísticos de simulação.

Segundo Isaaks e Srivastawa (1989), através do procedimento de simulação estocástica, é possível obter vários campos aleatórios do fenômeno espacial em estudo, tornando possível a modelagem da incerteza, através da geração de múltiplas realizações dos valores dos atributos distribuídos no espaço. A incerteza espacial é obtida, portanto, através desse conjunto de imagens consideradas igualmente representativas do fenômeno.

A simulação é uma abordagem, em geral adotada para resolver problemas nos quais não se dispõe de solução analítica. Em um contexto mais amplo, a simulação refere-se à construção de modelos de qualquer natureza (físicos, matemáticos, sistemas produtivos e de distribuição) e simulação de cenários para o apoio à tomada de decisão. Em termos mais práticos, a simulação consiste na construção de um modelo de um sistema real (ou ainda por existir) e, através do uso do computador, torna possível a realização de experimentos com vários cenários deste modelo (SALIBY, 2001).

O modelo é gerado a partir de uma abstração do problema, onde estão envolvidas as variáveis consideradas (Figura 2.1). O nível de complexidade do modelo é diretamente

proporcional à abstração efetuada, ou seja, ao número de variáveis e a quais características serão utilizadas para a abstração (LOBATO, 2000).

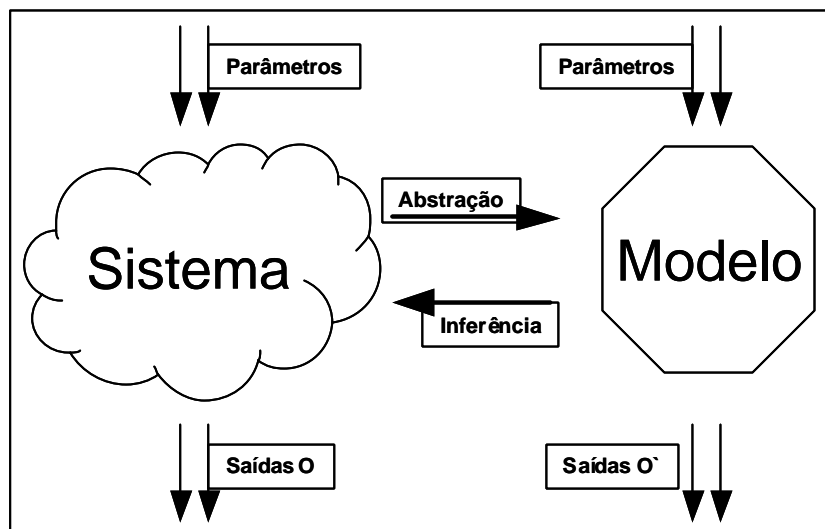


FIGURA 2.1 - Processo de abstração e inferência

Fonte: Adaptada de Lobato (2000, p.71).

Cada simulação corresponde a um cálculo determinístico, porém com os valores dos parâmetros amostrados a partir da função de distribuição de probabilidade definida a priori. A simulação estocástica ou probabilística de um sistema oferece meios para a geração de inúmeras seqüências independentes do fenômeno. Através de sorteios aleatórios, gera uma nova série, diferente, porém, com as mesmas propriedades estatísticas e igualmente prováveis. Com as séries distintas, entre si, são obtidos diversos resultados provenientes das simulações, ao invés de um único resultado, como ocorre no processo de estimativa.

Assim, torna-se possível que o planejador, por exemplo, tome sua decisão baseada não em um evento isolado, mas na análise probabilística do fenômeno estudado (FONSECA, 2004). A característica principal da simulação é a capacidade de reproduzir a variância dos dados de entrada, tanto no sentido univariado (via histograma) quanto espacialmente (através do variograma ou outro modelo de covariância) (VANN et al., 2002).

Na prática de SIG, muitas operações são usadas em seqüência para gerar valores de um atributo, os quais resultam de um modelo computacional. Um modelo computacional é entendido aqui como uma representação matemática simplificada da realidade. Por exemplo, o fluxo de um canal ser computado depois de processos hidrológicos terem sido traduzidos em equações matemáticas. Neste caso, a realidade é aproximada por um modelo computacional adequado e a utilização de um SIG para a avaliação de modelos computacionais é identificada pelo termo *modelagem espacial* em SIG (HEUVELINK, 1998). Neste trabalho o termo é adotado, subentendendo o conceito apresentado.

Independente da modelagem, ser ou não tratada em SIG, se os parâmetros que serão amostrados estiverem determinados e uma função de distribuição de probabilidade apropriada, por exemplo, através de um dos procedimentos geoestatísticos, estiver definida, as simulações estocásticas podem ser efetuadas.

A literatura apresenta (PEBESMA e HEUVELINK, 1999; HELTON e DAVIS, 2003 & WILMOT, 2003;) três métodos que podem ser usados para amostragem das funções de distribuição de probabilidade: método de Monte Carlo ou amostragem aleatória simples, amostragem estratificada e amostragem por hipercubos latinos (Latin Hypercube Sampling-LHS).

Quando se utiliza uma variável aleatória com distribuição de probabilidade conhecida, o método de Monte Carlo é um método freqüentemente empregado como uma técnica de amostragem. De acordo com Metropolis e Ulam (1949) & Fishman (1995), a amostragem por Monte Carlo procura reproduzir um processo aleatório utilizando simulação, por isso, muitas vezes é denominado simulação de Monte Carlo.

Uma variante particular da simulação utilizando método de Monte Carlo define um modelo de simulação geoestatística, apresentado em Deutsch e Journel (1998). O procedimento conhecido como simulação seqüencial condicionada, usa a fdac (estimada por krigeagem) para obter valores $z(\mathbf{u})$, de uma VA Z , em cada posição $\mathbf{u} \in A$. O condicionamento considera os dados amostrais originais e também os valores pré-simulados dentro da vizinhança de \mathbf{u} .

O método de Monte Carlo foi apresentado por Heuvelink (1998) como uma forma de avaliar a propagação de incertezas em modelagem espacial, considerando dados espaciais representados por campos numéricos. Neste contexto, tem sido abordado na literatura, em atributos espaciais manipulados em SIG (HEUVELINK e BURROUGH, 2002; KRIVORUCHO e CRAWFORD; 2003 & ORTIZ et al., 2004).

O procedimento da simulação seqüencial condicionada é adotado na metodologia deste trabalho e será tratado no próximo item.

2.2.4.1 Simulação Seqüencial Condicionada – Avaliação de Incerteza

A geoestatística oferece basicamente duas abordagens de simulação seqüencial condicionada: i) a simulação seqüencial paramétrica; ii) a simulação seqüencial não-paramétrica. Do ponto de vista do método de simulação seqüencial condicionada, a diferença básica entre essas duas abordagens consiste na forma de estimar a fdac univariada, como apresentado no item 2.2.2, podendo adotar a abordagem paramétrica ou não.

Na simulação seqüencial condicionada paramétrica, a fdac é estimada a priori por um conjunto limitado de parâmetros, como ocorre com a distribuição gaussiana (item 2.2.2.1) e é, neste caso, denominada simulação seqüencial gaussiana. Este método, no entanto, requer a hipótese de multi-normalidade dos dados, uma suposição de difícil verificação e que pode não ser apropriada para modelagem do fenômeno em estudo. Mais detalhes desta abordagem podem ser vistos em Goovaerts (1997) & Deutsch e Journel (1998).

A simulação seqüencial condicionada não-paramétrica não requer que a fdac seja estimada a priori. Neste caso, para cada localização u a simular, a fdac é obtida por um conjunto de valores estimados que representam uma aproximação discretizada do modelo de distribuição de cada VA, conforme apresentado no item 2.2.2.2. Este procedimento é realizado empregando-se o formalismo por Indicação (vide Apêndice A) e é denominado simulação seqüencial condicionada por indicação. Mais detalhes

desta abordagem podem ser vistos em Goovaerts (1997); Deutsch e Journel (1998) & Felgueiras (1999).

Das duas abordagens de simulação seqüencial condicionada, a paramétrica e a não-paramétrica, este trabalho optou por empregar o método simulação seqüencial condicionada por indicação. A razão desta escolha é que este procedimento de simulação não impõe nenhum tipo de distribuição de probabilidade a priori para as VA que serão utilizadas no processo de modelagem espacial. A estimativa da VA $Z(\mathbf{u})$, por simulação seqüencial condicionada por indicação, apresentada em Camargo (2007), ocorre na seguinte seqüência:

Definição de valores de cortes, denotado por z_k , $k = 1, \dots, K$, sobre o conjunto de dados $\{z(\mathbf{u}_i), i = 1, \dots, N\}$. Por exemplo, para 3 valores de cortes poderia ser: $z_1 =$ primeiro quartil, $z_2 =$ segundo quartil e $z_3 =$ terceiro quartil.

Para cada valor de corte z_k estabelecido, transforma-se a VA $Z(\mathbf{u}_i)$ em uma variável indicadora, denotada por $I(\mathbf{u}_i; z_k)$, como já apresentada na equação 2.3. Obtém-se, assim, um conjunto de valores $\{i(\mathbf{u}_i), i = 1, \dots, N\}$ da VA $I(\mathbf{u}_i; z_k)$, e:

1. Para cada conjunto $\{i(\mathbf{u}_i), i = 1, \dots, N\}$ da VA. $I(\mathbf{u}_i; z_k)$, define-se um modelo teórico de semivariograma;
2. Aplicação do método SSI para obtenção de um conjunto de imagens equiprováveis ou igualmente representativas do campo aleatório $Z(\mathbf{u})$;
3. Construção da fdac de $Z(\mathbf{u}_i)$, em cada localização \mathbf{u}_i ?a partir do conjunto de imagens simuladas. O procedimento da simulação seqüencial condicionada por indicação está resumido na Figura 2.2.

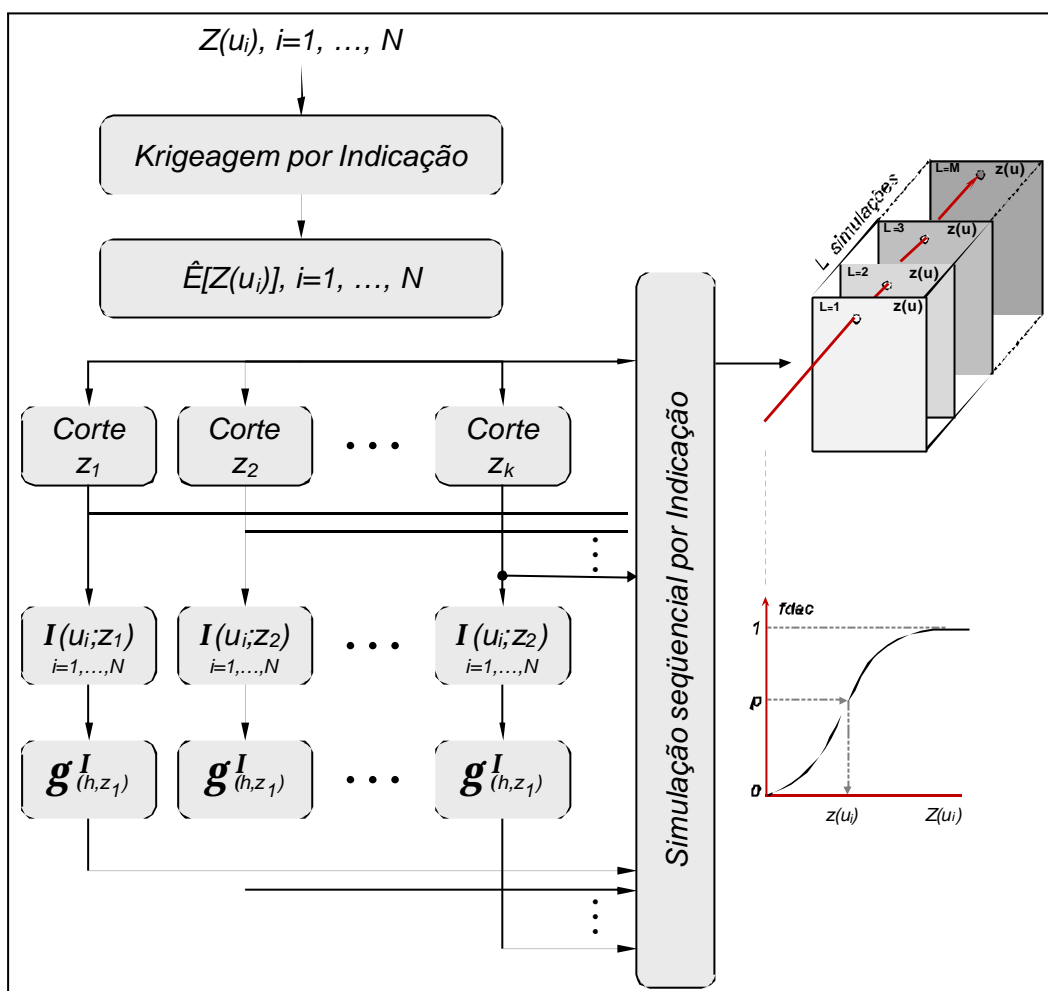


FIGURA 2.2 - Síntese do procedimento para construção das fdac para realizar a simulação seqüencial por indicação.

Para avaliar a incerteza espacial nas estimativas espera-se que os modelos simulados por geoestatística, honrem os valores nos pontos amostrados e reproduzam as mesmas características de dispersão dos dados originais. Desse modo, os modelos de simulação estocástica buscam reproduzir a variabilidade do conjunto de amostras e a continuidade espacial da variável em estudo, do mesmo modo que os variogramas ou a covariância; essas condições, segundo Goovaerts (1997) e Srivastawa (1989), não são abrangidas pelos modelos de krigagem.

A característica do condicionamento na simulação, ao considerar os dados amostrais originais e também os valores pré-simulados dentro da vizinhança de u , faz com que esse procedimento seja mais completo que o da krigagem no que se refere ao modelo

de covariância. As fdac estimadas por krigeagem estão condicionadas apenas às amostras, caracterizando a incerteza estimada a partir dessas, como local. As fdacs estimadas por simulação consideram também os valores pré-simulados, permitindo informação sobre a incerteza conjunta das variáveis (FELGUEIRAS, 1999).

Um processo de simulação, ao reproduzir L campos equiprováveis do atributo avaliado, pode dar origem à função de distribuição de probabilidades do atributo que está sendo simulado. A análise de incerteza de um atributo de um dado recurso ou de um fenômeno pode, portanto, ser efetuada através da sua função de distribuição de probabilidades. Neste ponto, retoma-se o conceito do método de Monte Carlo.

A partir da distribuição de probabilidades determinada por um dos métodos anteriores, o método de Monte Carlo pode ser adotado para realizações aleatórias do atributo e também, para obter realizações da VA resultante de uma modelagem espacial.

A idéia principal do método de Monte Carlo, para avaliar a propagação de incertezas na modelagem espacial, é obter realizações VA de saída Y a partir de realizações, das M VA de entrada Z_i , $i=1, \dots, M$, obtidas a partir da distribuição conjunta destas variáveis. Os valores realizados de Y são calculados pela aplicação de uma função g sobre os valores realizados das entradas. A função g denota um modelo matemático, por exemplo, que integra as M VA para obter Y . O modelo de incerteza de $Y(u)$, em cada posição u , é obtido a partir dos valores realizados para $Y(u)$.

As estatísticas, a partir do modelo de incerteza local, a média e variância de Y são calculadas, em u , conforme as expressões 2.11:

$$\mathbf{m}(u) = \frac{1}{N} \sum_{i=1}^N y_i(u) \quad e \quad \mathbf{g}^2(u) = \frac{1}{N-1} \sum_{i=1}^N (y_i(u) - \mathbf{m}(u))^2 \quad (2.11)$$

Uma consideração importante neste processo diz respeito ao número de realizações da VA em cada posição u . Segundo Heuvelink (1998), pesquisas em SIG têm sido realizadas com o método de Monte Carlo com apenas 20 ou 10 realizações. Trabalhos mais recentes, como o desenvolvido pela PUC (2007), demonstram que o erro na

estimativa, ao adotar simulação de Monte Carlo pode ser representado pelo desvio padrão da simulação dividido pela raiz quadrada do número de simulações. Assim, quanto menor o desvio da simulação, maior a precisão dos resultados. Como o erro da estimativa é inversamente proporcional ao tamanho da amostra, melhores estimativas requerem maiores amostras e, portanto, mais realizações para amostrar. O trabalho de Santos e Ferreira (2003), sugerem mais do que 100 realizações.

Quando o número de simulações aumenta, as variâncias decrescem rapidamente no início e gradualmente vão se tornando estáveis. O número no qual as variâncias tendem a se tornarem estáveis pode ser escolhido como número total de simulações e os detalhes estatísticos desta colocação podem ser encontrados em Goovaerts (1997).

Até aqui a simulação foi apresentada considerando uma VA, entretanto, muitas aplicações da modelagem espacial utilizam-se de modelos matemáticos compostos por mais de uma variável, o que requer a determinação de distribuições de probabilidade conjuntas para avaliação das incertezas. Uma simulação conjunta, ou co-simulação, de atributos deve ser considerada quando a interdependência dos atributos no modelo utilizado é importante para representar adequadamente o fenômeno.

A determinação de uma *fdac* conjunta, seguindo a abordagem geoestatística, é possível através do procedimento de cokrigagem. Este procedimento, apresentado em Goovaerts (1997) e Ortiz et al. (2004), requer a inferência dos semivariogramas diretos e cruzados para todas as variáveis do modelo utilizado. Quando a abordagem por indicação é adotada, determinar muitos semivariogramas diretos e cruzados torna-se custoso operacionalmente. Estes variogramas devem ser inferidos para cada corte adotado na definição da *fdac*, de modo que, quanto maior o número de variáveis, mais trabalhoso se torna o procedimento. De acordo com Deutsch e Journel (1998), o problema da co-simulação reside na inferência e modelagem da matriz de covariância cruzada, o que torna o procedimento trabalhoso para o usuário.

Pérez e Journel (1991), sugeriram um método para substituir o sistema de co-krigeagem, ao propor a krigagem das Principais Componentes (PC). A transformação por PC é baseada na correlação existente entre os dados. Deriva da matriz de covariância entre os

dados originais e gera um novo conjunto de dados denominados componentes principais, ou fatores. Os valores obtidos são combinações lineares dos valores originais. A conceituação matemática do método está amplamente abordada em Richards (1996).

O procedimento definido por Pérez e Journel (1991), consiste em efetuar múltiplas krigeagens, porém, das PC das variáveis originais. Os autores demonstram que o método é capaz de reproduzir uma fdac condicional equivalente à obtida por cokrigeagem, porém, com substancialmente menos esforço de modelagem de variogramas e menor custo computacional.

A maioria dos algoritmos de simulação pode ser generalizado, ao menos em teoria, para simulação conjunta de várias variáveis, ao considerar uma função aleatória vetorial do tipo $Z_M(\mathbf{u}) = \{Z_1(\mathbf{u}), Z_2(\mathbf{u}), \dots, Z_M(\mathbf{u})\}$. O problema está, segundo Deutsch e Journel (1998), na inferência e modelagem da matriz de covariância cruzada, $\Sigma = [C_{M,M'}] = [Cov\{Z_M(\mathbf{u}), Z_{M'}(\mathbf{u})\}]$.

Ao substituir a simulação das M variáveis dependentes, $Z_M(\mathbf{u})$, pela simulação de M fatores independentes, $Y_M(\mathbf{u})$, as variáveis Z originais necessitam ser reconstituídas. Assim, se $Y = \mathbf{j}(Z)$, então, $Z = \mathbf{j}^{-1}(Y)$ e $z_M^l(\mathbf{u}) = \mathbf{j}^{-1}(y_M^l(\mathbf{u}))$. Segue também que $y_M^l(\mathbf{u}) = [y_1^l(\mathbf{u}), \dots, y_M^l(\mathbf{u})]$ é o conjunto de fatores independentes simulados e $z_M^l(\mathbf{u}) = [z_1^l(\mathbf{u}), \dots, z_M^l(\mathbf{u})]$ é o conjunto de valores simulados resultante, onde a interdependência é garantida pela transformada inversa comum \mathbf{j}^{-1} (PEREZ e JOURNEL, 1991 & DEUTSCH e JOURNEL, 1998).

Exceto para casos específicos onde fatores Y estiverem baseados em relações não lineares evidentes, a maior parte das aplicações pode considerar fatores lineares baseados em uma decomposição ortogonal da matriz de covariância Σ das M variáveis originais $Z_M(\mathbf{u})$. A decomposição da matriz de covariância, segundo Deutsch e Journel (1998), é dada por $\Sigma_{(h_0)} = [Cov\{Z_M(\mathbf{u}), Z_{M'}(\mathbf{u} + h_0)\}]$ e corresponde a um

simples vetor de separação h_0 . As correlações cruzadas de Z são reproduzidas somente para este vetor específico de separação. A distância zero, $h_0=0$, é frequentemente escolhida por conveniência, sendo o argumento tal que a correlação cruzada é máxima para a distância $h_0=0$.

Goovaerts (1997), mostra que os estimadores krigagem e a co-krigagem são idênticos se as M variáveis envolvidas forem mutuamente (duas a duas), espacialmente independentes. O autor demonstra que, por construção, os M fatores das componentes principais, $Y(\mathbf{u})$, são ortogonais no lag $|h|=0$: $Cov\{Y_M(\mathbf{u}), Y_M(\mathbf{u}+h)\}=0$, " $M^{-1} M'$ ", onde M representa a M -ésima componente em \mathbf{u} .

Em teoria, a condição é satisfeita se as M variáveis são intrinsecamente correlacionadas. A correlação entre as variáveis é dita intrínseca quando não muda com a escala. Ou seja, a ortogonalidade se estende a todos os outros vetores de separação \mathbf{h} : $Cov\{Y_M(\mathbf{u}), Y_M(\mathbf{u}+h)\}= C_{MM}(\mathbf{h})=0$, " $M^{-1} M'$ ", \mathbf{h} , (WACKERNAGEL, 1998). No entanto, Goovaerts (1997), mostra que checar se as variáveis são intrinsecamente correlacionadas pode ser efetuado através da avaliação de um correlograma cruzado entre as principais componentes e que esta correlação cruzada não deve ultrapassar um máximo de 0.3, entre os pares.

2.3 Tomada de Decisão Considerando Modelos de Incerteza e Risco

Segundo Druck et al. (2002), o processo inferencial visa calcular uma estimativa do valor $z^*(\mathbf{u})$, através de um estimador. Esse estimador, no que se refere aos objetivos do processo inferencial, deve minimizar algum tipo de erro, que se deseja evitar, e maximizar os acertos de interesse. Um bom estimador para um valor de $z(\mathbf{u})$ é aquele para o qual o erro (e), ou a diferença entre o valor estimado e o verdadeiro, $e = z^* - z(\mathbf{u})$, estará próximo de zero.

De acordo com Journel (1989), para cada possível valor de $z(\mathbf{u})$ e cada possível estimativa $z^*(\mathbf{u})$, pode-se associar a perda ou o impacto do erro, através de uma função de perda, denominada $L(e)$. Quanto maior a distância entre $z^*(\mathbf{u})$ e $z(\mathbf{u})$, maior a perda.

Assim, pode-se definir uma estimativa ótima como a estimativa que minimiza a perda esperada.

No entanto, minimizar $L(e)$ implica em conhecer o valor verdadeiro, $z(\mathbf{u})$. Como este valor é desconhecido, utiliza-se o modelo de incerteza definido pela fdac, através da simulação geoestatística por indicação, que representa a distribuição de $z(\mathbf{u})$, para determinar a perda esperada. A perda esperada $E[L(e)]$ é definida nas expressões (2.12) e (2.13), segundo Goovaerts (1997) por:

$$E[L(e)] = E\{L(e(\mathbf{u})) / (n)\} \quad (2.12)$$

$$E[L(e)] = \int_{-\infty}^{\infty} L(e(\mathbf{u})) dF(\mathbf{u}; z / (n)) \quad (2.13)$$

Na prática, segundo Journel (1989) e Druck et al (2002), a seguinte aproximação discretizada pode ser usada como na equação 2.14:

$$E[L(e)] \cong \sum_{k=1}^{K+1} L(z^*(\mathbf{u}) - z'_k) [F^*(\mathbf{u}; z_{k+1} | (n)) - F^*(\mathbf{u}; z_k | (n))] = \mathbf{j}(z^*(\mathbf{u})) \quad (2.14)$$

Onde: $z_k, k=1, \dots, K$ representam os K limiares que discretizam o conjunto de valores do atributo Z ; $z'_k = \frac{z_{k+1} + z_k}{2}$ e, em geral, $F(\mathbf{u}; z_{k+1} | (n)) = 1$.

A perda esperada definida em (2.13), calculada a partir do modelo $F(\mathbf{u}; z_k | (n))$, aparece como uma função $\mathbf{j}(z^*; \mathbf{u})$ do valor particular estimado z^* adotado. A estimativa ótima para a função de perda L é o valor $z_L^*(\mathbf{u})$ que minimiza a perda esperada $\mathbf{j}(z^*; \mathbf{u})$.

Portanto, a determinação de estimativas ótimas ocorre seguindo duas etapas (DRUCK et al., 2002):

1. a incerteza sobre o valor desconhecido $z(\mathbf{u})$ é inicialmente modelada pela sua fdac, $F(\mathbf{u}, z_k | (n))$ e,

2. a partir desse modelo, uma estimativa $z^*(\mathbf{u})$ é obtida de forma a minimizar $E[L(e)]$.

O valor ótimo $z_L^*(\mathbf{u})$, pode ser obtido para qualquer função de perda particular L . Segundo Journal (1989), mostra-se que para a função $L(e)=e^2$, isto é, para o critério dos mínimos quadrados, a melhor estimativa $z^*(\mathbf{u})$ ocorre quando z é o valor esperado, $z^*(\mathbf{u}) = z_E(\mathbf{u})$, da distribuição de probabilidade $F(\mathbf{u}; z_k | (n))$, também denominada estimativa tipo E, ou estimativa do valor esperado, conforme expressão (2.15).

$$z_E^*(\mathbf{u}) = \int_{-\infty}^{+\infty} z dF(z; \mathbf{u} | (n)) \quad (2.15)$$

Analogamente à definição apresentada em (2.13 e 2.14), a expressão (2.15) pode ser discretizada, utilizando a fdac a partir dos K valores de corte z_k , (JOURNAL, 1989), resultando a expressão (2.16).

$$z_E^*(\mathbf{u}) \approx \sum_{k=1}^K z_k' [F^*(z_{k+1}; \mathbf{u}(n)) - F^*(z_k; \mathbf{u} | (n))] \quad (2.16)$$

Segundo Justiniano (2004) a função quadrática é uma das funções simétricas de perda mais utilizadas e, neste caso, concordando com os autores anteriormente citados, a média da distribuição é o estimador que minimiza a perda esperada, quando se utiliza esta função.

O estimador de mínimos quadrados não é, no entanto, a única função de otimização de erros possível. Se for utilizada uma função de perda do tipo, $L(e) = |e|$, isto é, uma função de perda que é dada pelo valor absoluto dos erros estimados, mostra-se que o valor de z que minimiza a perda esperada, é a mediana da distribuição $F(\mathbf{u}; z_k | (n))$, definida na equação (2.17) por Journal (1989):

$$q_{0.5}(\mathbf{u}) = F^{-1}(0.5; \mathbf{u} | (n)), \text{ tal que } F(q_{0.5}(\mathbf{u}); \mathbf{u} | (n)) = 0.5 \quad (2.17)$$

Uma aplicação importante das estimativas ótimas é avaliar os diferentes impactos provocados por erros inferenciais do tipo subestimar ou superestimar. Se o impacto de superestimar deve ser diferenciado em relação ao impacto de subestimar, essas diferenças devem ser consideradas no processo de inferência. Desse modo, funções de perda assimétricas, do tipo definido em (2.18), podem ser utilizadas (GOOVAERTS e JOURNAL, 1995).

$$L(e) = \begin{cases} w_1 e & \text{para } e \geq 0 \\ w_2 |e| & \text{para } e < 0 \end{cases} \quad (2.18)$$

Journal (1989) e Cruz (2004), demonstram que para uma função linear de perda assimétrica, do tipo definido em (2.18), a melhor estimativa é o quantil-p da distribuição $F(\mathbf{u}; z_k/(n))$, conforme equação (2.19):

$$q_p(\mathbf{u}) = F^{-1}(p; \mathbf{u} | (n)) \quad \text{com } p = \frac{w_2}{w_1 + w_2} \in [0,1] \quad (2.19)$$

Onde, w_1 e w_2 medem o impacto relativo a superestimar ou subestimar, respectivamente.

Avaliar os riscos derivados dos erros de superestimar ou subestimar um valor pode ser tratado como avaliar os riscos de classificar uma localização u de modo inconveniente ou errada, diante do problema em mãos. Esses riscos foram definidos em Journal (1989) como riscos de falso positivo, $\alpha(u)$, e risco de falso negativo, $\beta(u)$.

- risco de um falso positivo ou o risco $\alpha(u)$, apresentado na equação (2.20): por exemplo, classificar erroneamente uma localização u como perigosa.

$$\begin{aligned} \mathbf{a}(\mathbf{u}) &= \Pr ob\{Z(\mathbf{u}) \leq z_c \mid z_L^*(\mathbf{u}) > z_c, (n)\} \\ &= F(\mathbf{u}; z_c | (n)) \end{aligned} \quad (2.20)$$

para todas as localizações \mathbf{u} , tal que a estimativa $z_L^*(\mathbf{u}) > z_c$.

- *risco de um falso negativo* ou o *risco $\mathbf{b}(\mathbf{u})$* :, apresentado na equação (2.21), por exemplo, classificar erroneamente uma classificação \mathbf{u} como segura.

$$\begin{aligned} \mathbf{b}(\mathbf{u}) &= \text{Pr ob}\{Z(\mathbf{u}) > z_c \mid z_L^*(\mathbf{u}) \leq z_c, (n)\} \\ &= 1 - F(\mathbf{u}; z_c \mid (n)) \end{aligned} \quad (2.21)$$

para todas as localizações \mathbf{u} , tal que a estimativa $z_L^*(\mathbf{u}) \leq z_c$.

Em um exemplo, apresentado por Goovaerts (1997), para avaliação de locais contaminados, supondo que a estimativa do tipo E, a média, tenha sido escolhida para delimitar as áreas indicadas para serem limpas, considerando um limiar de 1000 ppm de chumbo. Serão indicadas para recuperação, as áreas que excederem este limiar.

Duas questões podem ser levantadas:

- Qual é o risco $\alpha(\mathbf{u})$ de um falso positivo, isto é o risco de declarar uma localização como perigosa quando ela não é? Esse risco é derivado diretamente do modelo de incerteza, conforme a relação (2.20).
- Qual é o risco $\beta(\mathbf{u})$ de um falso negativo, isto é, o risco de declarar uma localização segura, quando não é? Esse segundo risco é também derivado do modelo $F(\mathbf{u}; z_k/(n))$, conforme a relação (2.21).

Goovaerts e Journel (1995), mostraram uma aplicação para minimizar o custo esperado de uma classificação errada, em áreas com deficiência de cobalto (Co) e cobre (Cu) no solo. Esse custo foi derivado da função de distribuição de probabilidade local condicionada (fdac), tanto para o Co quanto para o Cu. A aplicação de tratamentos corretivos para Co e Cu requer, no entanto, uma classificação a priori de cada localização como deficitária ou não desses.

A classificação das localizações como deficientes, ou não, dos metais considerados, pôde ser obtida aplicando limiares críticos, associados a valores de corte, na abordagem da geoestatística por indicação. No entanto, ao invés de usar somente limiares de probabilidade, cada localização pode ser classificada de modo que minimize o custo da perda esperada. Esta abordagem requer as fdac locais e funções econômicas para medir o custo de superestimar as concentrações de metal, o que poderia acarretar atraso no

crescimento das culturas e o custo de subestimar, que implicaria em aplicação desnecessária de tratamentos corretivos.

O custo associado à classificação da localização \mathbf{u} como deficiente é definido por Goovaerts (1997), como na função (2.22).

$$L_1(z(\mathbf{u})) = \begin{cases} 0 & \text{se } z(\mathbf{u}) < z_c, \text{ (classificação correta)} \\ w_1[z_c - z^*(\mathbf{u})] & \text{caso contrário} \end{cases} \quad (2.22)$$

Onde: w_1 é o custo relativo de subestimar concentrações de metal é dado em unidades financeiras/mg kg⁻¹; $z(\mathbf{u})$ é a concentração real do metal, $z^*(\mathbf{u})$ é a estimativa do metal, e z_c é o limiar crítico, no caso 1mg kg⁻¹ para Cu e 0.25 mg kg⁻¹ para o Co.

Se o solo em \mathbf{u} for realmente deficiente, $z(\mathbf{u}) < z_c$, a classificação está correta e não há perda devido à classificação errada. Se a localização estiver realmente com quantidades suficientes dos metais, $z(\mathbf{u}) = z_c$, a classificação acarreta aplicação indevida de Cu ou Co com adubos químicos, por exemplo, a um custo proporcional à diferença considerada [$z_c - z^*(\mathbf{u})$]. Essa nova classificação gera um novo mapa, baseado em custos.

O custo com a classificação da localização \mathbf{u} como suficiente, pode, de modo similar, ser dado pela equação (2.23):

$$L_2(z(\mathbf{u})) = \begin{cases} 0 & \text{se } z(\mathbf{u}) \geq z_c, \text{ (classificação correta)} \\ w_2[z_c - z(\mathbf{u})] & \text{caso contrário} \end{cases} \quad (2.23)$$

Se w_2 é o custo relativo de superestimar as concentrações de metal, esse custo é zero se o solo em \mathbf{u} estiver com metal suficiente, caso contrário, o custo será proporcional à deficiência real [$z_c - z(\mathbf{u})$]. Se o impacto (ou prejuízo) da classificação errada em uma localização considerada com metal suficiente for realmente maior que o custo da classificação errada da localização classificada como deficiente, então, w_2 receberá um peso maior.

Esta abordagem requer as funções locais e funções econômicas para medir o custo de superestimar as concentrações de metal, o que poderia acarretar atraso no crescimento das culturas e o custo de subestimar, que implicaria em aplicação desnecessária de tratamentos corretivos.

Um estudo realizado por Goovaerts e Journel (1995), sugere que em cada localização u , os custos esperados $j_1(z(u))$ e $j_2(z(u))$ sejam avaliados substituindo L_1 e L_2 , definidas em (2.22) e (2.23), em L na equação (2.14). A localização u passa, assim, a ser classificada de modo a minimizar o custo resultante esperado. O resultado da minimização de custos de uma classificação incorreta foi utilizado como um novo critério de reclassificação:

- u passa a ser considerado limpo se $j_2(u) > j_1(u)$, isto é, se os custos da classificação errada, ao considerar u como contaminado, forem superiores a $j_1(u)$.
- u passa a ser considerado contaminado se $j_2(u) < j_1(u)$, isto é, se os custos da classificação errada, ao considerar u como limpo, forem superiores a $j_2(u)$.

Os procedimentos inferenciais em mapeamentos direcionados ao planejamento econômico, sob o enfoque apresentado, dependem das funções de perda especificadas e dos parâmetros de custo utilizados nessas funções. Desse modo, diferentes cenários podem ser obtidos variando-se os valores desses parâmetros. Esses cenários representam as informações que devem auxiliar as atividades de planejamento e estão condicionados, por exemplo, aos recursos disponíveis que poderão ser despendidos, no caso de erros inferenciais.

O capítulo seguinte apresenta uma seqüência de procedimentos metodológicos, para definir cenários que devem auxiliar o usuário de SIG a tomar sua decisão. A escolha da melhor opção deve possibilitar que o tomador de decisão administre os riscos derivados dos procedimentos inferenciais por ele adotados na modelagem espacial.

CAPÍTULO 3

MODELAGEM ESPACIAL E TOMADA DE DECISÃO METODOLOGIA PROPOSTA

3.1 Introdução

Este capítulo apresenta a metodologia proposta para esta Tese. Possibilita a construção de cenários alternativos que auxiliem a tomada de decisão. A escolha de determinado cenário pode ser direcionada pelas incertezas e riscos de tomar uma decisão, em conjunto com aos recursos disponíveis para efetivar a decisão. No contexto deste trabalho, as incertezas e os riscos modelados por procedimento inferenciais geoestatísticos vão auxiliar na escolha dos cenários.

Considera-se neste estudo que, o usuário que vai planejar a utilização dos recursos disponíveis para uma determinada ação, necessita de uma seqüência de decisões, d_1, d_2, \dots, d_m . Propõe-se que as decisões, d_m , sejam compostas por um conjunto de indicadores ou parâmetros que envolvem tanto a informação não espacial quanto a informação espacial.

No que se refere à informação não espacial, os indicadores são caracterizados pelas alternativas das ações propostas, a_j , diante do problema em estudo. Estas alternativas devem levar em conta o planejamento voltado ao desenvolvimento produtivo da região e sua viabilidade econômica (ou custos envolvidos), aqui denominado v_j . Esta informação pode ser apresentada na forma de tabelas e relatórios.

Quanto à informação espacial é necessário fixar que ela está vinculada aos fenômenos que ocorrem no espaço geográfico, denominados aqui, fenômenos espaciais. Estes, devido à multiplicidade de fatores que integram, são, em geral, representados por modelos matemáticos que têm a finalidade de facilitar a sua compreensão. Para analisar tais fenômenos, a partir da modelagem de dados em SIG, ou modelagem espacial, deve-se considerar que, por natureza, estes dados são incompletos. A coleta de dados, os

quais servem de atributos de entrada desses modelos, é, em geral, restrita a amostras esparsas.

Desse modo, no que se refere à informação espacial, os indicadores ou parâmetros se associam à construção da informação. Os SIG vêm sendo utilizados com frequência (VISCARRA ROSSEL, et al., 2001 e CAMARGO, 2007) para construir a informação espacial através de procedimentos de espacialização. Estes procedimentos permitem gerar, a partir de amostras, superfícies contínuas dos atributos envolvidos na modelagem espacial e são abordados no decorrer deste capítulo.

Portanto, a obtenção desses indicadores ou parâmetros necessita de pesquisa em diversas etapas, as quais serão abordadas a seguir. A Figura 3.1 apresenta esquematicamente o problema a ser tratado para gerar cenários e tomar uma decisão, sob a óptica deste estudo.

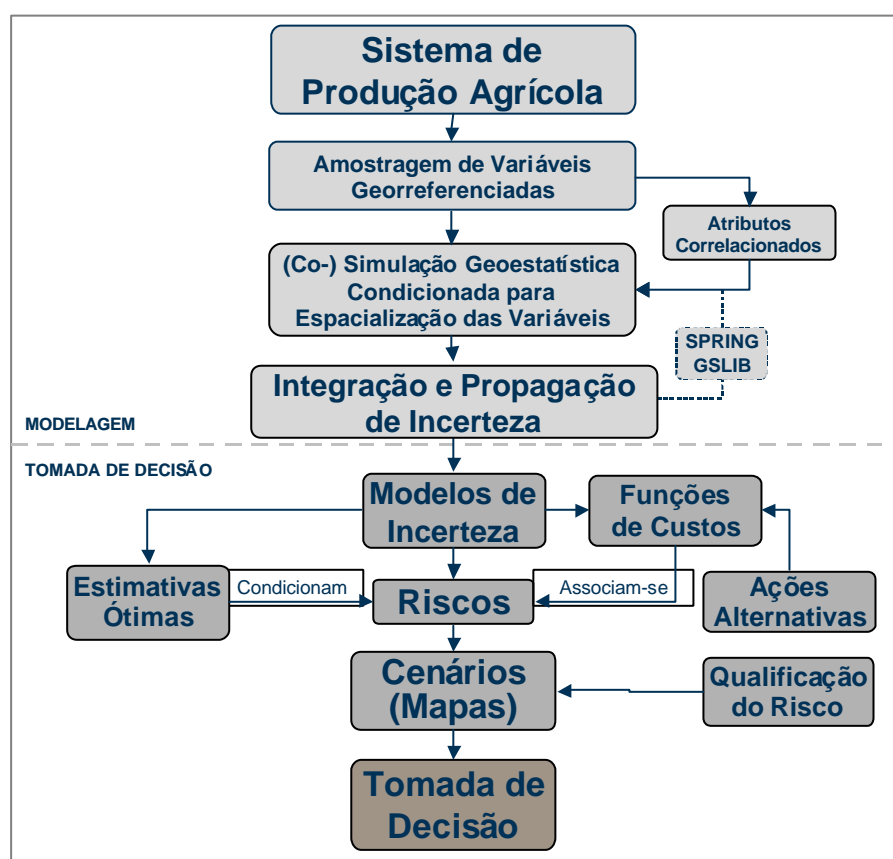


FIGURA 3.1 – Processo para tomada de decisão com base em modelagem espacial e construção de cenários de risco associados a funções de custo.

Duas fases compõem o processo apresentado na Figura 3.1: modelagem espacial e construção de cenários para tomada de decisão, os quais estão detalhados na seqüência.

3.2 Modelagem Espacial

A modelagem espacial, conforme definida no capítulo 2, item 2.3.4, refere-se à utilização de um SIG para efetuar operações de análise espacial, em modelos matemáticos que representam uma realidade geográfica.

A seguir, os procedimentos metodológicos adotados para realizar a modelagem espacial serão apresentados, juntamente com uma breve revisão sobre os dados envolvidos na modelagem, ou seja, os dados espaciais.

3.2.1 Dados Espaciais

Os fenômenos geográficos ou os recursos naturais como os solos, os aquíferos, a pluviometria de uma região, apresentam duas características comuns que indicam a aplicação de modelos probabilísticos: são entidades que se distribuem no espaço com certa estrutura, de modo não aleatório e a informação disponível, na forma de amostras ou observações sobre tais fenômenos espaciais, na maioria das vezes, é fragmentada e escassa e o conhecimento desses fenômenos sempre está associado à idéia de incerteza.

As amostras de um dado espacial são caracterizadas por sua posição, espaço temporal (x, y, z, t) e por atributos a ele associados. Por exemplo, um dado de temperatura pode ser observado em várias posições do espaço tridimensional (x, y, z) e em diferentes períodos de tempo “t”. As medidas de temperatura são os valores do atributo observado em posições desse sistema espaço temporal. Os atributos podem ter valores numéricos ou categóricos (associado a classes temáticas) (FELGUEIRAS, 1999).

Um dado espacial para ser trabalhado dentro de um SIG, deve ser representado por um modelo computacional. É comum, no ambiente de um SIG, a criação de estruturas de representação por grades regulares retangulares onde os valores do atributo nos vértices da grade são obtidos por espacialização, a partir do conjunto de amostras.

Segundo Felgueiras (1999), em um nível mais conceitual, computacionalmente, as grades regulares são representações do modelo denominado por Câmara e Medeiros (1998), como campos numéricos. Este modelo de campos numéricos é utilizado para representar dados espaciais cujos atributos têm distribuição contínua no espaço (temperatura, por exemplo). Estas estruturas são adotadas neste trabalho.

Dada a incompletude dos dados espaciais para quantificar as características de um recurso natural, por exemplo, é necessário dispor de procedimentos que façam uso dos dados espaciais disponíveis e permitam a inferência dos atributos em locais não amostrados. O procedimento de espacialização consiste em inferir valores do atributo, em posições não amostradas, a partir dos valores observados.

Dentre os algoritmos disponíveis em SIG para espacialização, estes podem ser determinísticos, como a média simples, ou a média móvel ponderada, ou estocásticos, como os da geoestatística. A geoestatística, objeto de estudo deste trabalho, apresenta dois procedimentos para espacialização conhecidos como krigagem e simulação condicionada. Destes, o procedimento de simulação condicionada foi adotado.

3.2.2 Simulação Conjunta de Múltiplas Variáveis

A espacialização através de simulação estocástica condicionada permite gerar campos aleatórios com características probabilísticas similares de um atributo. Ao adotar a abordagem geoestatística, neste procedimento a função de distribuição de probabilidade é inferida por krigagem em cada localização u de uma grade regular e é usada para se obter realizações para o valor do atributo.

Da mesma forma que é possível obter estimativas para os campos aleatórios individuais, gerados por procedimentos de krigagem, também é possível obter incertezas a partir das L realizações geradas por simulação estocástica condicionada. Essas medidas são locais, quando baseadas na distribuição univariada do atributo, definida pelos L valores simulados em uma localização. Quando, no entanto, as medidas de incerteza se baseiam na distribuição multivariada, definida por L campos simulados, são ditas incertezas globais ou conjuntas.

Neste trabalho, os L campos simulados são representados por L grades regulares em SIG e, além, da espacialização de atributos são utilizados para avaliar a incerteza propagada no processo de modelagem espacial e que se reflete no resultado final.

A fdac multivariada é usada para modelar a incerteza conjunta dos L valores simulados em \mathbf{u} . Como apresentado no capítulo 2, a fdac da simulação pode ser determinada por um método paramétrico ou não paramétrico, os quais definem a simulação seqüencial gaussiana e a simulação seqüencial condicionada por indicação, respectivamente.

No caso da simulação gaussiana, para cada bcalização \mathbf{u} a simular, a fdac é estimada pela média e variância obtidas diretamente dos estimadores de krigeagem. No entanto, este método requer a hipótese de multi-normalidade dos dados, uma suposição de difícil verificação e extremamente forte, que pode não ser apropriada, para modelagem do fenômeno em estudo. Mais detalhes desta abordagem podem ser vistos em Goovaerts (1997) & Deutsch e Journel (1998). Assim, a abordagem não paramétrica, por indicação, foi adotada neste trabalho.

O procedimento de co-simulação pode, também, ser realizado a partir de programas computacionais específicos que permitem realizações de uma variável aleatória, condicionada às realizações de uma outra variável aleatória. Tais procedimentos seguem uma abordagem da estatística bayesiana, que não é escopo deste trabalho, e está documentada em Diggle et al. (2003).

A modelagem espacial dos dados, nesta metodologia, leva em consideração, a existência ou não de correlação entre as variáveis para não simular valores em condições irreais. A correlação pode ser positiva, se altos valores de um atributo são associados a altos valores de um segundo atributo, ou negativa, caso contrário. Assim, este trabalho sugere a simulação das PC, uma adaptação do procedimento apresentado por Perez e Journel (1991) para krigeagem das PC (capítulo 2).

Entretanto, Como demonstrado em Goovaerts (1997) e Wackernagel (1998), as M variáveis envolvidas e os M fatores das componentes principais devem ser

espacialmente independentes (dois a dois) em $h=0$ e esta independência deve se estender para os demais vetores de separação h .

A existência de correlação intrínseca pode ser testada, de acordo com Wackernagel (1998), somente com os dados localizados onde os M atributos z_i são conjuntamente medidos, o que se denomina amostragem isotópica. A matriz de correlação do sistema de krigeagem das M variáveis $Z_i(\mathbf{u})$ é computada a partir de um conjunto de dados isotópicos. A amostragem isotópica ocorre quando, para variáveis diferentes, existem amostras na mesma posição geográfica (WACKERNAGEL, 1998). É um tipo de amostragem comum para propriedades químicas do solo ou geológicas, por exemplo. São, em geral, atributos que variam conjuntamente no espaço e que têm, portanto, uma correlação entre si.

Essa condição é checada ao avaliar se as variáveis são intrinsecamente correlacionadas. Essa condição é efetuada através de um correlograma cruzado entre as principais componentes e esta correlação cruzada não deve ultrapassar o valor de 0,3, entre os pares.

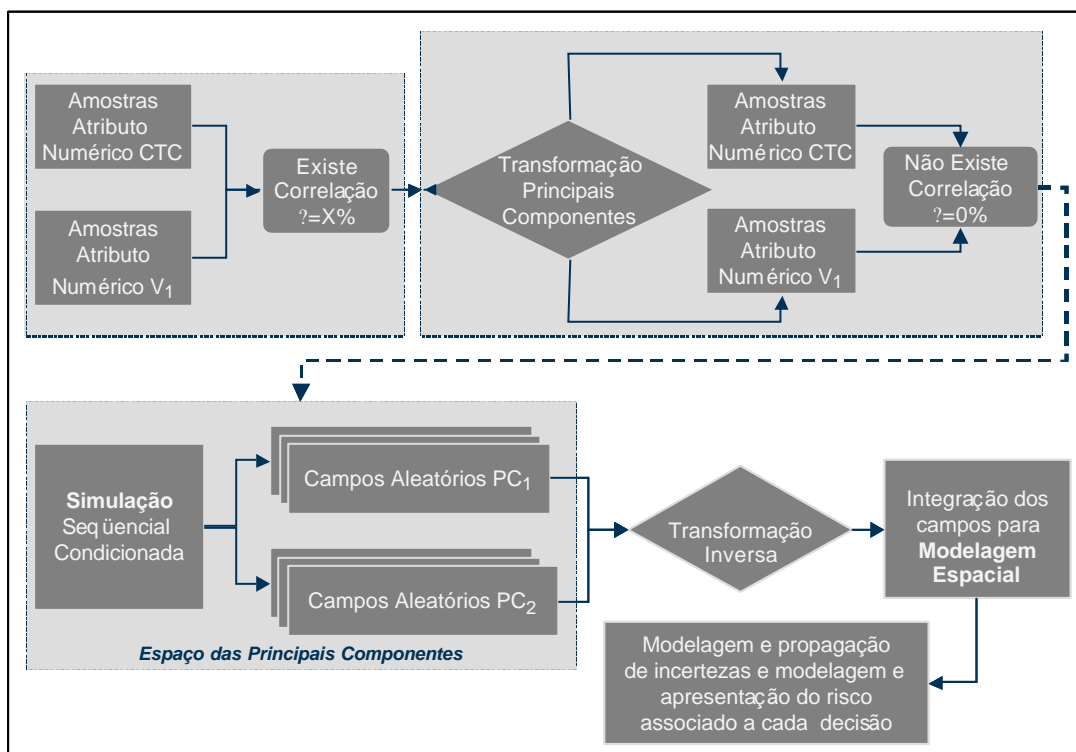


FIGURA 3.2 - Seqüência de processamento para realização da simulação conjunta.

A Figura 3.2 mostra a seqüência de procedimentos para efetuar a simulação das PC, a transformação inversa e iniciar a integração dos dados, seguindo as considerações elaboradas até este ponto.

A equação de transformação para o espaço das PC foi definida com base nas amostras das variáveis originais. O procedimento foi implementado e validado em planilha eletrônica (vide apêndice C). Após a implementação, a transformação inversa pode ser efetuada com facilidade. O procedimento substitui a simulação de M variáveis dependentes por M fatores independentes, a partir dos quais as variáveis originais correlacionadas podem ser reconstituídas.

Assim, propõe-se a adoção de um procedimento de simulação seqüencial condicionada, segundo a geoestatística por indicação, sobre os fatores resultantes do método das principais componentes e não diretamente sobre as variáveis do modelo. Para cada fator, um total de L realizações foi executado para cada ponto da grade. A transformada inversa dos fatores, pós-simulação no espaço das principais componentes, garante a correlação entre as variáveis originais. Obtém-se, assim, uma aproximação de uma simulação conjunta, porém, com menor esforço de modelagem de variogramas em relação ao procedimento de cokrigagem.

A solução foi adotada como uma forma simples e eficiente de contornar o problema da simulação conjunta, sem utilizar o estimador de cokrigagem para gerar uma fdac conjunta, em se tratando de variáveis correlacionadas.

3.2.3 Integração das Variáveis e Propagação de Incertezas

Após o procedimento de transformação inversa dos campos simulados para cada PC, a modelagem espacial vai envolver o SIG para operações locais, pontuais ou de vizinhança, que vão resultar em uma variável de saída da modelagem espacial. Esta variável de saída é definida pelo modelo matemático que representa o fenômeno que está sendo modelado e, portanto, é resultante da integração das VA de entrada que o definem.

Desse modo, para um dado modelo matemático, denominado g , que engloba operações aritméticas, entre M variáveis, com atributos $Z_i(\mathbf{u})$, pode-se dizer que o resultado da integração destas variáveis através de g , resulta uma nova variável $Y(\mathbf{u})$, conforme expressão 3.1.

$$Y(\mathbf{u})=g(Z_1(\mathbf{u}), \dots, Z_M(\mathbf{u})), \text{ onde } i=1, \dots, M \quad (3.1)$$

A Figura 3.3 mostra o processo de modelagem espacial para obter a fdac de $Y(\mathbf{u})$, seguindo a abordagem da simulação por indicação, a partir dos M atributos de entrada $Z_i(\mathbf{u})$.

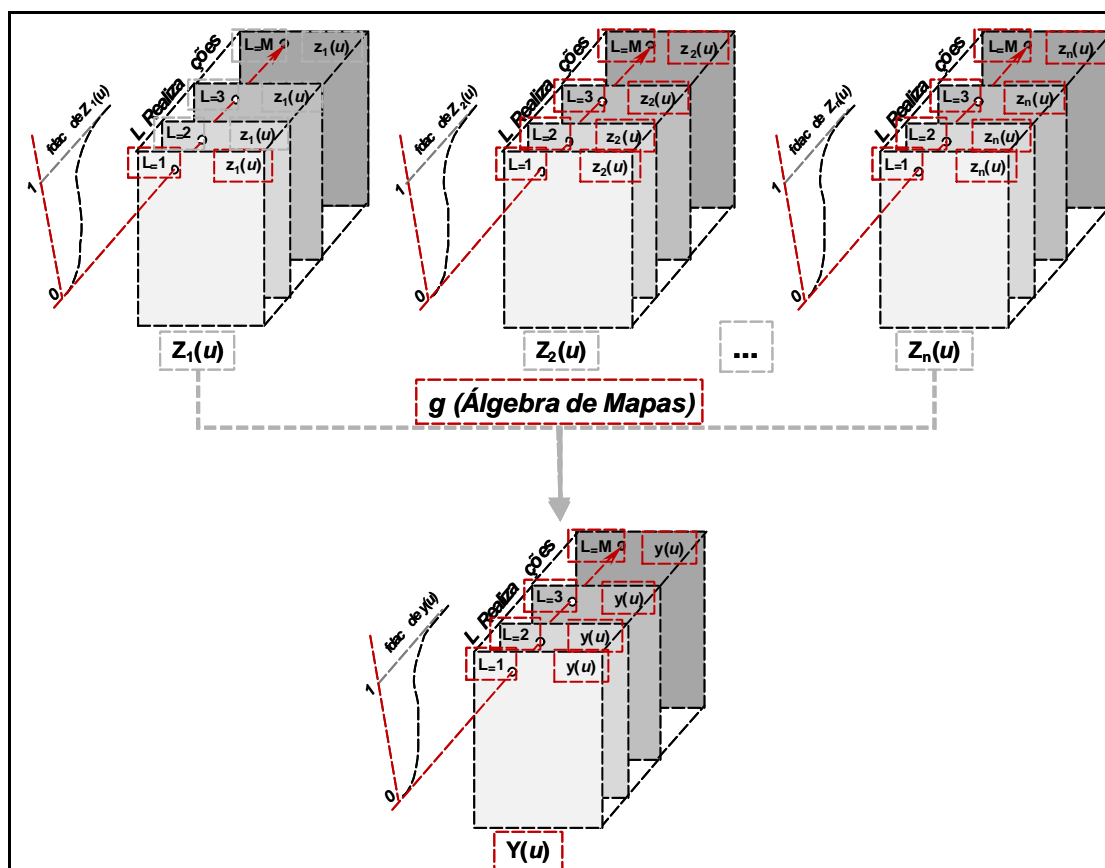


FIGURA 3.3 - Integração de campos de atributos numéricos simulados para gerar uma nova variável, Y.

A abordagem por indicação disponibiliza uma fdac para cada ponto da representação de grade, como ilustra a Figura 3.3. As fdac, construídas em cada localização espacial \mathbf{u} , dos campos aleatórios de Y, representam os modelos de incerteza de $Y(\mathbf{u})$. Conhecidos os campos de incerteza de cada uma das representações de entrada, pode-se, também,

obter um campo de incertezas do campo resultante $Y(\mathbf{u})$. Foi utilizado o método de amostragem aleatória da simulação de Monte Carlo, conforme apresentado em Heuvelink (1998), no capítulo 2, para integrar e avaliar a propagação de incertezas das VA de entrada no resultado da modelagem espacial.

3.3 Construção de Cenários para Tomada de Decisão

Os resultados do modelo simulado, L campos de $Y(\mathbf{u})$, com incertezas propagadas são, nesta fase da metodologia, utilizados para estabelecer cenários do problema espacial modelado. Estes cenários, associados aos riscos e aos custos envolvidos nas possíveis ações que serão efetuadas na área de estudo, vão conduzir à tomada de decisão considerada melhor.

Cada decisão deve estar vinculada a um cenário do fenômeno modelado. Portanto, a obtenção dos parâmetros que vão compor um vetor de decisão, $d_j, j=1, \dots, m$, requer da pesquisa, várias etapas de desenvolvimento da modelagem espacial. Resumidamente, até este ponto do trabalho, pode-se relacionar uma etapa inicial que diz respeito ao experimento ou amostragem e que determina a coleta de amostras georreferenciadas dos atributos que serão modelados. Uma segunda etapa que determina qual procedimento de espacialização será adotado para gerar representações contínuas dos atributos. Essas representações serão integradas no modelo para gerar os cenários buscados pela pesquisa. Uma terceira etapa, que vai associar modelos de incerteza e risco aos cenários, os quais associados a custos financeiros, terminam de compor uma alternativa de decisão.

Na terceira etapa, considera-se que:

- A **Decisão** é um vetor composto dos seguintes parâmetros ou indicadores: $d_j=(a_j, v_j, r_j, c_j)$, onde $j=1, \dots, m$.
 - O elemento a_j representa a j -ésima alternativa de ação proposta para ocorrer desenvolvimento produtivo;

- O elemento v_j representa os custos envolvidos e está vinculado à alternativa a_j ;
- O elemento r_j é o risco definido a partir da propagação das incertezas da modelagem espacial, e se associa a v_j ; e
- O elemento c_j representa o cenário proposto para planejamento, sendo gerado em função de a_j , v_j e r_j .

Os cenários definem uma coleção de “mapas”, construídos a partir de um conjunto de imagens igualmente representativas geradas por simulação seqüencial condicionada por indicação. A decisão efetuada sobre um determinado cenário tem como potencial diferenciador a incerteza e o risco modelados por geoestatística, associados a funções de custo que definem a viabilidade econômica da ação.

Determinadas as fdac de cada atributo de entrada e também do resultado da modelagem espacial, além das estimativas, modelos de incerteza podem ser associadas às inferências. Algumas abordagens para otimizar ações em tomadas de decisão, utilizando o resultado da modelagem com incertezas associadas, podem ser aplicadas e são agregadas à metodologia.

O princípio clássico envolvido em uma tomada de decisão corresponde à identificação de ações que maximizam a possibilidade de obter resultados desejáveis e minimizam a possibilidade de ocorrerem resultados indesejáveis Hastie (2001). Neste ponto, este trabalho coloca uma questão importante que se refere à escolha das estimativas ótimas ($z_L^*(\mathbf{u})$). Este conceito, apresentado no capítulo 2, é utilizado na construção dos cenários.

Freqüentemente, os usuários de SIG procuram gerar mapas da variável resultante da modelagem, Y , utilizando o estimador de média. Este trabalho coloca em foco a utilização de estimadores ótimos, não necessariamente o estimador de média, que tem seu critério de ótimo definido pelo método dos mínimos quadrados, mas outros

estimadores ótimos que podem ser adequados aos diferentes propósitos de decisão que utilizam procedimentos inferenciais.

Uma aplicação importante das estimativas ótimas é avaliar os diferentes impactos provocados por erros inferenciais do tipo subestimar (estimar um valor menor do que seria o valor real) ou superestimar (estimar um valor maior do que seria o real). Se o impacto de superestimar é diferenciado em relação ao impacto de subestimar, essas diferenças devem ser consideradas no processo de inferência. Desse modo, funções de perdas assimétricas, como as apresentadas no capítulo 2 podem ser utilizadas (GOOVAERTS e JOURNAL, 1995 & CRUZ, 2004), para definir outros estimadores ótimos.

A construção dos cenários se inicia ao estimar os valores de y_u , onde se propõe considerar os erros que decorrem do processo de inferência. Estes erros, superestimar e subestimar o valor de um atributo, não devem ser tratados como se apresentassem os mesmos impactos.

A minimização de um ou de outro, vai depender dos objetivos do trabalho a ser executado. A adequabilidade de uma estimativa depende do uso que se pretende fazer desta estimativa. Para um dado modelo de incerteza, diferentes estimativas podem ser obtidas, dependendo da função de perda escolhida.

O estimador de krigagem linear, por exemplo, conforme a literatura (ISAAKS e SRIVASTAWA, 1989; DEUTSH e JOUNEL, 1998 & FELGUEIRAS, 1999), minimiza a variância, conforme já abordado, considerando uma função de perda simétrica. Portanto, considera que os impactos de subestimar e superestimar são equivalentes. Desse modo, os estimadores ótimos definidos por funções assimétricas seriam preferidos para apoiar decisões que devem considerar os diferentes efeitos provocados por estes erros.

Um modo prático de pensar, dado um problema, no qual o erro de superestimar causa uma conseqüência mais desastrosa, financeiramente ou ambiental, do que o erro de subestimar é buscar estimativas que possam reduzir as conseqüências desse erro.

Reportando a equação (2.19), capítulo 2, que define o estimador do quantil, uma possibilidade de reduzir tais conseqüências é atribuir um peso maior para o erro que se apresenta mais importante. Sabendo que $p = \frac{w_2}{w_1 + w_2} \in [0,1]$, define o quantil, se $w_1 > w_2$ implica que, um estimador ótimo, nestas condições, deve ser menor do que a mediana ($p= 0.5$). Numericamente pode-se pensar em $w_1= 0.8$ e $w_2= 0.2$ e, portanto, a estimativa ótima seria considerada o quantil 20% ou q_2 . Os parâmetros w_1 e w_2 medem o impacto relativo a superestimar ou subestimar, respectivamente.

Portanto, a primeira consideração que esta metodologia coloca é que mesmo para um mapa, que apresente apenas estimativas de uma única variável, $Z(\mathbf{u})$, ou de uma variável resultante de modelagem espacial, $Y(\mathbf{u})$, o usuário de SIG deve se preocupar em definir qual a estimativa ótima para o seu problema.

A Figura 3.4 mostra uma seqüência para facilitar a avaliação do planejador quanto às estimativas ótimas, em função dos erros que deseja evitar. A partir da fdac constituída das realizações da simulação diferentes estimativas podem ser calculadas. Se o problema em mãos requer minimizar o erro de subestimar, porque suas conseqüências serão mais desastrosas do que superestimar, o planejador pode escolher o estimador do quantil superior, e assim por diante.




FIGURA 3.4 - Escolha do estimador ótimo, pelo planejador, em função do erro inferencial que deseja controlar.

Uma segunda abordagem é envolver o tomador de decisão com o conceito de estimador ótimo, porém, buscando extrair mais informações para auxiliá-lo. O planejador tem um problema para resolver e diante deste problema, um quadro com algumas questões pode ajudá-lo a entender melhor qual tipo de erro (subestimar ou superestimar, ou mesmo nenhum) não é aceitável para uma decisão adequada. Neste sentido, sugere-se que algumas questões sejam incorporadas ao processo de planejamento como mostra a Tabela 3.1.

Tabela 3.1 - Avaliação do planejador quanto as possíveis conseqüências dos erros de superestimar e subestimar

<i>Incerteza</i>	Vai precisar de intervenção?
<i>Superestimar</i>	É melhor superestimar?
<i>Subestimar</i>	É melhor subestimar?
Quatro Possibilidades de Decisão	
Decidir corretamente	Intervir e acertar
Decidir corretamente	Não intervir e acertar
Decidir erroneamente	Intervir e errar
Decidir erroneamente	Não intervir e errar

A partir da escolha do estimador ótimo que melhor se adapta ao problema, os mapas que vão compor os cenários de atuação podem ser gerados de modo que os riscos de comprometimento financeiro, provocados pelos erros de superestimar ou subestimar sejam incorporados aos mapas. Esses riscos podem ser entendidos como classificações erradas, como mostra a Figura 3.5.

	Estima-se que Necessita	Estima-se que Não Necessita		Estima-se que Necessita	Estima-se que Não Necessita
Necessita	CLASSIFICAÇÃO CORRETA	Falso (-) Erro de Subestimar	Necessita	CLASSIFICAÇÃO CORRETA	RISCO β
Não Necessita	Falso (+) Erro de Superestimar	CLASSIFICAÇÃO CORRETA	Não Necessita	RISCO α	CLASSIFICAÇÃO CORRETA

FIGURA 3.5 - Associação dos erros de superestimar e subestimar com os riscos $\alpha(u)$ e $\beta(u)$.

Avaliar os riscos de uma classificação errada, decorrentes dos erros inferenciais pode, também, conduzir a decisões mais elaboradas. Esses riscos de classificação podem ser

avaliados a partir do modelo da fdac, $F(\mathbf{u}; z_c/(n))$, de acordo com as equações (2.20) e (2.21), no capítulo 2, as quais definem os riscos $\mathbf{a}(\mathbf{u})$ e $\mathbf{b}(\mathbf{u})$.

Tanto o risco $\mathbf{a}(\mathbf{u})$ como o risco $\mathbf{b}(\mathbf{u})$ são derivados do modelo de incertezas definido anteriormente. O risco $\mathbf{a}(\mathbf{u})$ corresponde à probabilidade acumulada em z_c , ou seja, $Prob \{Z(\mathbf{u}) \leq z_c\}$ e essa condição, é válida apenas para as estimativas (ótimas) que apresentam valores superiores ao limiar de probabilidade considerado, z_c . Ou seja, $z_L^*(\mathbf{u}) > z_c$, e por isso, é denominado também, falso-positivo.

Quanto ao risco $\mathbf{b}(\mathbf{u})$, este só ocorre onde um $\mathbf{a}(\mathbf{u})$ não ocorre, dado que, $z_L^*(\mathbf{u}) \leq z_c$, por isso, denominado falso negativo. É definido como $\mathbf{b}(\mathbf{u}) = 1 - F(\mathbf{u}; z_c/(n))$ para todas as localizações \mathbf{u} , tal que as estimativas válidas em \mathbf{u} são apenas aquelas que apresentam valores inferiores ou iguais ao limiar de probabilidade considerado, z_c .

A avaliação dos mapas de riscos $\mathbf{a}(\mathbf{u})$ e $\mathbf{b}(\mathbf{u})$ oferece ao planejador a possibilidade de ordenar, por exemplo, as áreas prioritárias para tomar uma decisão. Esses mapas ao apresentarem os erros de classificação, que ocorrem em função dos procedimentos inferenciais adotados evidenciam espacialmente a ocorrência de falso positivo ou de falso negativo, os indicam a probabilidade do ponto \mathbf{u} estar classificado errado, indicando uma ação desnecessária naquela localização.

Uma opção é avaliar as áreas com riscos $\mathbf{b}(\mathbf{u})$ elevados, para que sejam as primeiras candidatas a reamostragem, por exemplo. Essa atitude pode diminuir gastos, conforme será abordado a seguir.

Uma terceira possibilidade é apresentada ao planejador para que ele possa avaliar, também, o impacto econômico de duas possíveis decisões, usando o conceito de funções de perda, porém, associando os parâmetros w_1 e w_2 a custos financeiros.

Uma função de perda quantifica o impacto ou a perda que ocorre ao estimar um valor desconhecido, z^* . O mesmo conceito da função de perda aplicada aos estimadores ótimos é aqui empregado. Como já abordado no capítulo anterior, esta perda está

associada ao erro e , que é definido pela diferença entre o valor estimado e o valor verdadeiro. Não se dispondo do valor verdadeiro, sugere-se utilizar o modelo de incerteza da VA que está sendo estimada, o qual é estimado por simulação seqüencial por indicação.

As funções de perda, não necessariamente, são utilizadas apenas para minimizar o erro da estimativa e definir um estimador ótimo. Podem, também, ser constituídas para que cada localização u seja classificada de modo que minimize as perdas econômicas esperadas, decorrentes da classificação efetuada em u . Essa classificação é decorrente dos limiares de corte definidos pelo usuário em função seu problema. Se, em função desse limiar, a classificação estiver correta, a perda econômica é zero. Caso contrário esta perda pode ser associada a um custo financeiro que deve permitir ao tomador de decisão direcionar as medidas necessárias de modo mais racional.

Esta abordagem requer as fdaç locais e funções econômicas para medir o custo provocado pelo erro de superestimar ou subestimar a VA, e avaliar o que poderia acarretar em termos financeiros, cada um desses erros. Um mapa ou cenário mostrando algumas possibilidades das implicações financeiras de cada escolha, em função dos erros inferenciais, pode ajudar a contabilizar custos ou perdas e direcionar medidas controladoras, por exemplo.

A função de perda, nestes casos, deve ser especificada pela empresa ou organização envolvida no problema, ou mesmo pelo responsável da área por decisões econômicas. De acordo com os exemplos apresentados no capítulo 2, dependendo dos pesos atribuídos a w_1 e w_2 pode-se especificar funções de perda adequadas e definir uma conduta mais conservadora ou mais agressiva de ação.

O custo ou a perda da classificação errada é expresso em um mapa que indica, em cada localização, u , da representação de grade definida, o valor dessa perda. É evidente que, diante da possibilidade de avaliar cenários diferentes, ações mitigadoras podem ser conduzidas, não apenas em uma localização u da grade, mas em blocos que definem áreas de atuação mais ampla. Nesta fase, as funções de análise espacial do SIG são importantes.

Esta Tese propõe algumas funções de custo, baseadas no problema abordado no estudo de caso apresentado no capítulo 4. São funções simples que poderão servir de base para o usuário de SIG que se deparar com um problema semelhante.

Os procedimentos inferenciais em mapeamentos direcionados ao planejamento econômico, sob o enfoque apresentado, dependem das funções de perda especificadas e dos parâmetros de custo utilizados nessas funções. Desse modo, diferentes cenários podem ser obtidos variando-se os valores desses parâmetros. Esses cenários representam as informações que devem auxiliar as atividades de planejamento e estão condicionados, por exemplo, aos recursos disponíveis que poderão ser dispendidos, no caso de erros inferenciais.

Para cada localização \mathbf{u} , os custos ou perdas esperadas, $\mathbf{j}(z(\mathbf{u}))$, para uma dada função L , podem ser avaliados, substituindo L pelas funções L_1 e L_2 definidas nas equações (2.24) e (2.25), capítulo 2. Torna-se possível, assim, obter $\mathbf{j}_1(z(\mathbf{u}))$ e $\mathbf{j}_2(z(\mathbf{u}))$ e cada localização \mathbf{u} passa a ser classificada de modo a minimizar o custo resultante esperado. Esse conceito é aplicado para gerar um outro cenário que reflete os custos envolvidos ao minimizar ou não os erros oriundos da classificação de \mathbf{u} , a partir das funções L definidas no estudo de caso.

O resultado da minimização de custos de uma classificação errada pode ser adotado como um novo critério de reclassificação. Esta abordagem é, também, utilizada como mais um procedimento metodológico para constituir cenários diferentes, ampliando a capacidade de análise do planejador.

Uma abordagem que integra as anteriores define uma proposta estruturada para planejamento de uma área, oferecendo ao usuário SIG, parâmetros ou indicadores que vão compor um vetor de decisão.

O usuário de SIG pode obter cenários de atuação, derivados de modelagem espacial e a cada cenário, c_j , obtido segundo os procedimentos acima apresentados, dispor de um vetor de decisão, d_j . Juntamente com os mapas que definem espacialmente os cenários de atuação para o planejador propõe-se que o vetor de decisão d_j seja composto por

outros parâmetros. Este vetor deve conter parâmetros ou indicadores relacionados à cada ação proposta, a_j e aos custos relacionados à esta ação, v_j .

As ações estão totalmente relacionadas à escolha de estimadores ótimos para espacialização e, portanto, estão associadas aos erros inferenciais abordados, e à minimização dos custos econômicos envolvidos na concretização destas ações. Por outro lado, o risco, r_j , de tomar uma decisão equivocada, deriva dos modelos de incerteza gerados na espacialização e, também, se associa aos custos econômicos, através das funções de perda. Ao ser quantificado e espacializado, r_j , também vai compor o vetor d_j . Propõe-se, portanto, que o vetor de decisão tenha seguinte constituição: $d_j=(a_j, v_j, c_j, r_j)$, onde $j=1, \dots, m$.

Nesta proposta agrega-se o conceito de gestão de riscos, sugerido pela norma AS/NZS 4360:2004. Esta norma foi elaborada pelo comitê de gestão de riscos da Standarts Austrália e Standarts New Zeland (QSP, 2004). Uma adaptação desta norma foi elaborada para o contexto deste trabalho, de modo que, o vetor d_j engloba este conceito, além dos parâmetros definidos anteriormente, na forma de tabelas.

Os mapas delimitam, em função de a_j , v_j e r_j , áreas aptas para planejamento imediato ou não. O tomador de decisão pode lançar mão de um mapa de probabilidades, com a finalidade de direcionar o tomador de decisão antes de qualquer ação efetiva. Um limiar de probabilidade, definido pelo planejador, que deve conhecer bem as necessidades impostas pelo problema avaliado, define áreas com maior ou menor incerteza para efetuar uma atividade ou não. Por exemplo, limpar uma região tomada por metal tóxico.

O nível de toxicidade é que indica um limiar físico, por exemplo, acima de 0.5 ppm (partes por milhão) de cobre, o solo é considerado tóxico. Porém, a probabilidade de aceitação é definida pelo tomador de decisão, por exemplo, 70%. Assim, se a localização avaliada apresentar 70% de probabilidade exceder o limiar de 0.5ppm, é considerada tóxica e a decisão é limpar. Porém, no caso da probabilidade de exceder o limiar de toxicidade ser em torno de 30%, qual seria a decisão? Esses limiares de aceitação acabam sendo subjetivos e para cada problema o usuário deve avaliá-lo com critérios próprios.

De posse desse tipo de mapa, o tomador de decisão dispõe de uma visão ampla do seu campo de ação: as áreas com maior probabilidade de ocorrência de um determinado problema podem ser priorizadas para ação imediata ou não, dependendo da gravidade, urgência ou mesmo das condições financeiras.

No entanto, se além dos mapas, o planejador tiver disponível, de forma resumida, o que expressa cada cenário de avaliação diante das ações propostas, acredita-se que a decisão será agilizada e melhor efetuada.

Através de um experimento, voltado para a agricultura de precisão, esta proposta metodológica é exemplificada e apresentada no capítulo 4.

CAPÍTULO 4

DEFINIÇÃO E ANÁLISE DE CENÁRIOS DE RISCO EXPERIMENTO – CORREÇÃO DE ACIDEZ DO SOLO COM CALCÁRIO

4.1 Introdução

A acidez do solo é um dos fatores que mais limitam a produtividade das culturas em várias partes do mundo, inclusive no Brasil. Os solos brasileiros, na sua maioria, são ácidos, destacando-se aqueles sob vegetação de cerrado. Tais solos são caracterizados por baixas concentrações de cálcio e de magnésio, os quais são elementos que estão diretamente envolvidos no desenvolvimento das raízes, e por valores elevados de alumínio trocável e baixa disponibilidade de fósforo do solo (PITTA et al., 2006).

Nos solos ácidos existem problemas de deficiência e/ou toxidez nutricional, baixa capacidade de retenção de água e baixa atividade dos microrganismos. Os solos com essas características apresentam baixa produtividade em estado natural. Para incorporação desses solos ao processo produtivo é indispensável o uso adequado de corretivos como calcário e adubos (FAGEIRA, 2001).

O calcário é o produto mais utilizado para a neutralização do alumínio tóxico e para o fornecimento de cálcio e magnésio para as plantas (NOLLA et al., 2005). A calagem⁸ depende, no entanto, da tomada de decisão de se aplicar ou não calcário. Caso seja verificada essa necessidade deve-se definir a dose média, no caso da agricultura convencional, ou as doses variáveis, no caso da agricultura de precisão.

O desenvolvimento ou adaptação de cultivares mais tolerantes à acidez do solo utilizando-se melhoramento genético, não elimina o uso do calcário na agricultura, pelos seus efeitos e sua importância nos diferentes níveis tecnológicos dos diversos sistemas de produção usados no Brasil. A recomendação de calagem não é um

⁸Calagem - prática que permite a diminuição da acidez do solo mediante a incorporação ao mesmo de substâncias com características de corretivo de acidez (cal, gesso e calcário) (EMBRAPA, 2003).

procedimento simples, pois pressupõe o conhecimento de um número razoável de informações adicionais, como sugere Pitta et al. (2006):

- Características da propriedade agrícola (caracterização da área, da cultura);
- Tipo de solo;
- Histórico da área;
- Expectativa de rendimento;
- Conhecimento tecnológico (tem sua origem na pesquisa naquela região ou estado);
- Informações oriundas das condições do mercado, principalmente àquelas relacionadas aos preços de insumos e;
- Disponibilidade de crédito.

O sucesso do manejo da acidez dos solos não depende somente do conhecimento básico sobre a teoria da acidez e de características dos corretivos. A prática da calagem envolve um conjunto de operações ligadas à distribuição e incorporação do calcário nos solos. Entretanto, de nada adianta a recomendação de calagem ter sido feita com a melhor base teórica possível, se o corretivo for aplicado em dose incorreta (QUAGGIO, 2004).

Nos últimos anos, vem aumentando o interesse dos agricultores brasileiros por sistemas de manejo de solo mais conservacionistas como o preparo reduzido e, principalmente, o plantio direto. Esses sistemas propiciam o menor revolvimento possível do solo e, assim, afetam diretamente a prática da calagem a ponto de o calcário ser aplicado à superfície do solo, sem incorporação, no caso do sistema de plantio direto. A distribuição do corretivo de acidez deve ser a mais uniforme possível, em qualquer sistema de manejo do solo. De acordo com Quaggio (2004), é fácil observar quando se distribui o calcário de maneira desuniforme em solos mais ácidos, pela irregularidade no crescimento das plantas. Nos solos com menor grau de acidez, há efeito negativo na produtividade, porém de percepção mais difícil.

Houve interesse no passado de alguns agricultores brasileiros, principalmente aqueles arrendatários de terra, no sentido de reduzir os custos com a calagem, mediante a aplicação de pequenas doses de calcário, finamente moído, no sulco de plantio. Na mesma época, trabalhos de pesquisa foram realizados e mostraram que tal prática era pouco eficiente, sobretudo em solos com acidez elevada (BEN et al., 1981). Além disso, nessa condição, a média de produtividade se manteve baixa no período de quatro anos (BEN et al., 1983).

Artigos apresentados por Oliveira e Pavan (1996); por Caires et al. (2003) e pela Embrapa Solos (2004), mostram que os tratamentos sem incorporação de calcário apresentam produtividades inferiores de milho, trigo e soja em relação aos tratamentos com incorporação do calcário.

Vários são os artigos encontrados na literatura mostrando a relação do calcário com o aumento de produção. A boa produtividade das culturas de grãos, principalmente soja, trigo e milho, está associada à adubação correta (reposição de nutrientes no solo) e à correção da acidez do solo (FUKUDA e OTSUBO, 2003). O cálculo da necessidade de calcário (NC) é de extrema importância para uma boa produção de grãos de soja e trigo (KORNDORFER et al., 2004).

No esforço de reduzir os custos de produção, a agricultura de precisão surgiu, no contexto da atividade agrícola, graças ao desenvolvimento e disponibilidade de algumas tecnologias, entre as quais lista-se o sistema de posicionamento global (GPS), os sensores de produtividade, técnicas de sensoriamento remoto, análise espacial em SIG e sistemas de aplicações de insumos a taxas variáveis. Trata-se de um conceito relativamente recente, de manejo do solo e da cultura, que se baseia no princípio da aplicação localizada de insumos, em função dos diferentes níveis de nutrientes disponíveis no solo evitando-se, assim, excesso ou falta de insumo em locais específicos da área (CASTRO e TORRE, 2005).

A condição elementar que rege a adoção da agricultura de precisão - e de tecnologias de aplicação com taxas variáveis em particular, segundo Nolla et al. (2005), diz respeito à variabilidade espacial. A agricultura de precisão pode ser entendida como uma maneira

não convencional de conduzir o processo produtivo, quando as práticas agrícolas são encaradas sob a perspectiva da variabilidade espacial, em contraste com a aceitação de valores médios para o tratamento dos campos e das culturas.

Sob o enfoque do manejo localizado de fertilidade, a prática da agricultura de precisão pode afetar tanto os custos de insumos quanto o faturamento da produção, uma vez que a detecção da variabilidade, em uma escala técnica e economicamente viável, permitiria a redistribuição ou mesmo a redução dos insumos nos pontos em que os níveis estiverem adequados.

Teoricamente, o manejo desta variabilidade poderia resultar em uma produção otimizada, ao mesmo tempo em que havendo redução no uso de insumos, reduziria as possibilidades de possíveis impactos ambientais, decorrentes do uso excessivo e descontrolado destes insumos. Entretanto, mesmo havendo variabilidade, pode não fazer sentido a adoção de práticas localizadas. Antes, é preciso conhecer os níveis de variações dos atributos do solo e da cultura; os níveis de variação do solo afetam a produtividade ou sua qualidade; e, se é possível obter informações suficientes e, também, as tecnologias adequadas para manejar a variabilidade de modo rentável.

Entre as diversas maneiras de conduzir a investigação da variabilidade destacam-se a amostragem de solo em malha (*grid*), os mapeamentos, de plantas daninhas e de condutividade elétrica, a compactação do solo, o acompanhamento do desenvolvimento da cultura por sensoriamento remoto e, de forma mais difundida, o mapeamento da produtividade por ocasião da colheita. Após identificar o nível de variação de atributos, considerando-se inclusive a variação temporal, o passo mais importante seria encontrar as relações de causa e efeito entre os atributos do solo e os dados de produtividade. Desde que a variabilidade dos atributos de solo relevantes para o controle da produtividade de culturas seja suficientemente conhecida e manejada, haverá uma perspectiva de elevação do nível de produtividade e/ou menor intensidade de uso de insumos, melhorando a relação custo benefício.

Neste contexto de auxiliar o tomador de decisão quanto à aplicação de corretivos no solo, e considerando-se as informações levantadas nos parágrafos anteriores e a

metodologia apresentada no capítulo 3, este capítulo apresenta um estudo de caso que avalia métodos baseados em modelagem espacial, propagação de incertezas e modelos de risco para a necessidade de calcário do solo.

4.2 Experimento

São considerados fatores clássicos relacionados à produção agrícola: a terra, o trabalho e o capital disponível (SOUZA e LOBATO, 1999). Contudo, um quarto fator de produção deve ser acrescentado, os conhecimentos tecnológicos, provenientes de pesquisas que podem melhorar ou otimizar decisões. O experimento a seguir tem esta finalidade e foi possível, graças ao apoio da empresa de consultoria e assessoria agrícola IMPAR (<http://www.imparag.com.br>).

4.2.1 Área de Estudo

A área disponibilizada para o desenvolvimento deste trabalho é parte da Fazenda Figueira, no município de Carambeí, que se localiza na região centro-leste do Estado do Paraná, (Figura 4.1).

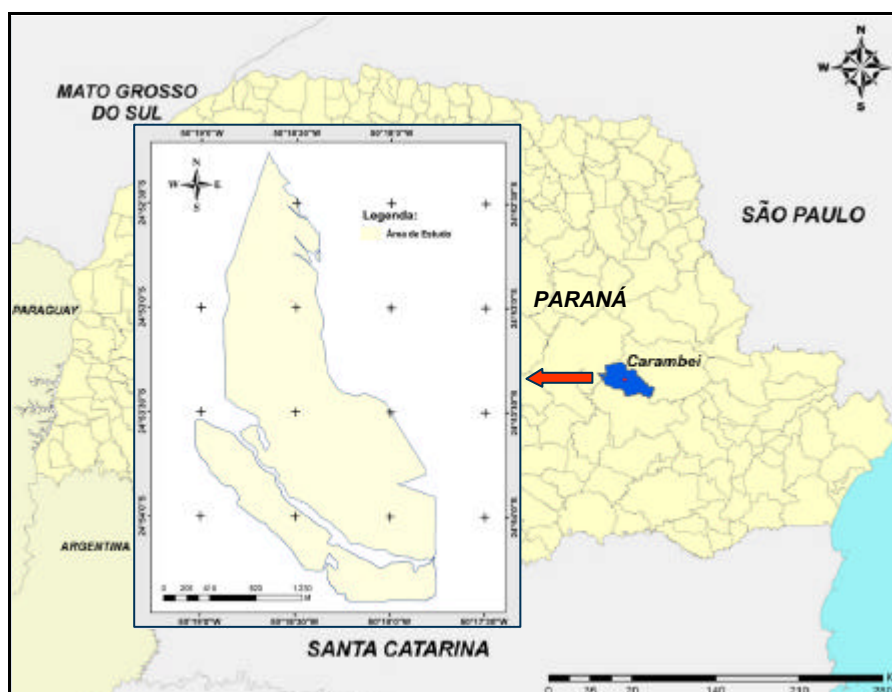


FIGURA 4.1 - Área de Estudo – parte da fazenda Figueira no município de Carambeí, Estado do Paraná.

O município de Carambeí, segundo estudo especificamente realizado por (BOGNOLA et al., 2002), encontra-se sob a influência de um clima subtropical úmido, com chuvas bem distribuídas ao longo do ano. Os tipos de solos predominantes na área são os Latossolos Vermelhos e Cambissolos.

Nestas condições de solo e clima a fazenda adota o sistema de agricultura de precisão, sendo que a principal atividade agrícola está relacionada ao plantio das culturas de Soja, Trigo e Milho. A área corresponde a este estudo é de aproximadamente 392 ha (3,92Km²), o que equivale a seis talhões de um total de 29 talhões de área plantada.

A baixa fertilidade dos solos encontrados na região, segundo Fageira (2001), é um fator limitante à produção agrícola, porém, de acordo com Bognola et al. (2002), com aplicações adequadas de corretivos e fertilizantes, aliadas à época propícia de plantio dos diversos cultivares obtêm-se boas produções.

Esses solos caracterizam-se, também, pela alta acidez e, por vezes, a presença de alumínio em níveis tóxicos. Essa acidez deve ser corrigida para que o solo se torne adequado ao plantio e retorne boa produtividade. Medidas corretivas, como a aplicação do calcário em doses recomendadas, tornam possível reduzir a acidez e obter um melhor aproveitamento dos fertilizantes e adubos (MIRANDA et al., 2005).

Conforme abordado anteriormente, a correção da acidez do solo, através da prática da calagem, contribui de forma relevante para o aumento da produtividade e da renda agrícola, em função dos benefícios que traz às propriedades químicas, físicas e biológicas do solo (QUAGGIO et al., 1996 e FAGEIRA, 2001).

4.2.2 A Calagem no Estado do Paraná

A calagem depende da decisão de se aplicar ou não o calcário e da definição de doses de calcário, caso seja constatada a necessidade. Utiliza-se de indicadores de acidez tais como, pH, saturação de bases (V%), saturação de alumínio (Al) e alumínio trocável (Al+H) para definir a necessidade e dosagem de aplicação (NOLLA et al., 2005),

através de alguns métodos, formulados matematicamente e que têm a ver com as características dos solos de cada região do Brasil.

Dentre os vários métodos para recomendação de calagem, no Brasil são utilizados principalmente três: neutralização do alumínio, solução tampão e a saturação de bases (RAIJ, 1991; LOPES, 1991 e BOGNOLA et al., 2002).

O método de saturação de bases, apresentado por Raij (1991), é atualmente usado no Estado do Paraná, definido como o mais adequado para a região, e por razão da localização da área de estudo, apenas este será abordado neste trabalho. Baseia-se na relação existente entre Saturação de Bases e Capacidade de Troca Catiônica (CTC). No modelo são considerados parâmetros referentes ao solo, ao corretivo e à cultura em questão.

De acordo com a Fukuda e Otsudo (2003) esse método teve origem no Estado de São Paulo, em trabalhos de Catani e Gallo (1955), seguidos por Raij et al. (1979) e, por último, a versão atualmente em uso, proposta por Quaggio et al. (1983). É baseado na correlação do pH do solo com a saturação de bases e requer, em rotina laboratorial, a determinação de cálcio (Ca), magnésio (Mg) e potássio (K), e algumas vezes sódio (Na), além da determinação de hidrogênio e alumínio (H+Al) (acidez potencial), ajustados ao pH 7.0. O método consiste, portanto, na elevação da saturação de bases trocáveis para um valor que proporcione o máximo rendimento econômico do uso do calcário.

O processo para gerar mapas de aplicação localizada de calcário, seguindo o método de saturação de bases, requer que os atributos do solo, V% e CTC, que sevem de entrada no modelo, sejam amostrados com georreferenciamento, de modo a obter representações contínuas destas variáveis através de procedimentos de inferência espacial. Em se tratando de agricultura de precisão, os SIG são os sistemas mais utilizados para esta finalidade.

4.2.3 Modelo para Estimar a NC

A estimativa da NC é feita a partir da análise química do solo e os métodos atualmente em uso visam não somente a redução da acidez do solo, mas o melhor retorno econômico para a maioria das espécies cultivadas.

A escolha do calcário, o valor neutralizante, o grau de finura e sua reatividade são fatores relevantes na aquisição do material corretivo. O poder neutralizante é determinado pela comparação com o poder de neutralização do carbonato de cálcio puro (CaCO_3), que é de 100%. Por essa razão, é denominado de Poder Relativo de Neutralização Total (PRNT) ou equivalente de carbonato de cálcio. O conhecimento deste parâmetro, o PRNT, é de grande importância na determinação da NC (QUAGGIO et al., 1983).

Segundo Quaggio et al. (1983), a saturação de bases, V%, é variável para cada Estado ou região e, como já definido anteriormente, para o Estado do Paraná este valor é de 70%. Nos demais Estados da Região Central, formados basicamente por solos sob vegetação de Cerrados, o valor considerado adequado de saturação é 50%.

O modelo matemático definido para o cálculo da NC, em toneladas/hectare (t/ha), passa a ser representado pela expressão (4.1), segundo recomendações da Embrapa solos em Fukuda e Otsudo (2003):

$$NC(\text{tha}^{-1}) = \frac{(V_2 - V_1) * CTC}{PRNT} \quad (4.1)$$

Onde:

V_1 = valor da saturação das bases trocáveis originais do solo, dadas em porcentagem, antes da correção; são amostrados diretamente do solo, analisados em laboratório e devem ser elevados até o nível considerado adequado para a cultura e solo em questão.

V_2 = Valor da saturação de bases trocáveis que se deseja atingir; existe um valor padrão para cada cultivar. Neste experimento, devido às características do solo, para as culturas de soja, trigo e milho, o valor adotado é de 70%.

A CTC representa a soma das bases Ca, Mg, K e Na, com os valores da acidez potencial (H + Al).

PRNT é o Poder Relativo de Neutralização Total do calcário usado; depende da jazida que foi extraído o calcário e como, em geral, é menor que 100% (equivale a neutralização total).

O calcário usado na fazenda Figueira apresenta um PRNT de 85%. Trata-se da escolha mais viável em termos técnicos e econômicos, segundo a empresa IMPAR (2005). A indústria de calcário coloca no mercado produtos com ampla variação na granulometria, nos teores de cálcio e magnésio e no PRNT. Cabe ao técnico, com base na análise de solo, na exigência da cultura e no preço do calcário, analisar as várias alternativas oferecidas e decidir qual a solução mais adequada. A decisão final, entre outras informações, o preço por tonelada efetiva, é uma variável de grande interesse e é, segundo a IMPAR (2005), muito influenciada pela proximidade ou não da mineradora.

Os valores de saturação de bases (V%) continuam expressos em porcentagem, porém o cálculo da NC, de acordo com Raij (1991) e Fukuda e Otsudo (2003), deve levar em consideração a unidade adotada para CTC, para que o valor da NC resultante seja expresso em toneladas por hectare (t/ha). Os autores mostram que se a CTC foi medida em $\text{mmol}^{(9)}/\text{dm}^3$, como é o caso das amostras deste estudo, há necessidade de dividir as concentrações medidas por 10, de modo que se tornem equivalentes a $\text{mEq}^{(10)}/100\text{ml}$, pois assim, a NC calculada será expressa em t/ha. Pois, os autores demonstram que $1\text{mEq}/100\text{cm}^3$ equivale 1t/ha. Se 1cm^3 corresponde a 1ml, então, $1\text{mEq}/100\text{cm}^3$ equivale $1\text{mEq}/100\text{ml}$, que por sua vez, segundo definição dos autores, equivale a 1t/ha.

9 A unidade do Sistema Internacional (SI) para quantidade de matéria é o mol. O mol é definido como "a quantidade de matéria de um sistema que contém tantas unidades elementares quantos forem os átomos contidos em 0,012 kg de Carbono-12". As unidades SI para concentração, (C), são mol/m³. Também são válidos cmol (centimol) e mmol (milimol), (ANDRADE e CUSTÓDIO, 2000).

10 O equivalente é uma unidade utilizada em química que pode ser definido como a massa em gramas de substância que pode reagir com um mol de electrons. O termo mEq é a medida em termos de miliequivalencia do soluto por litro ou ml do solvente.

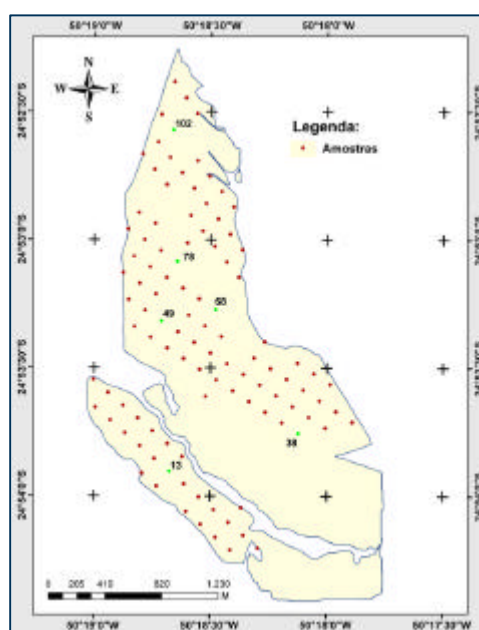
Portanto, o modelo a ser utilizado para cálculo da NC passa a ser definido como na equação 4.2.

$$NC = \frac{(70 - V_1) * CTC}{85 * 10} \quad (4.2)$$

4.2.4 Descrição e Disponibilidade dos Dados

A empresa de consultoria e assessoria agrícola IMPAR, fornecedora dos dados deste trabalho, utiliza uma extensão do SIG ArcGis, especificamente um módulo de gerenciamento agrícola o SStoolbox, desenvolvido pela empresa SST Development Group (<http://www.sstsoftware.com>). Este sistema é adotado para a espacialização das propriedades do solo segundo os procedimentos de krigeagem (descrito em GOOVAERTS, 1997; FELGUEIRAS, 1999 e ESRI, 2008) sendo que este sistema não exige muita interação do usuário. Este fato pode ser um facilitador para o usuário, mas também, pode ser um complicador, a partir do momento em que não é possível definir e ajustar os parâmetros, por exemplo, os variogramas.

Os dados de fertilidade do solo utilizados neste trabalho foram amostrados em campo, na fazenda Figueira no ano de 2005 e analisados em laboratório definindo os seguintes parâmetros: Saturação de bases (V%), Capacidade de Troca Catiônica (CTC), Fósforo (P), Matéria Orgânica (MO), pH_{CaCl2}, H⁺Al, Potássio (K), Cálcio (Ca), Manganês (Mg) e Ferro (Fe).



PONTO	LATITUDE	LONGITUDE	P resina (mg/dm ³)	Mat. Org. (%)	pH CaCl ₂	m%	H+Al	K	Ca	Mg	CTC	V%
13	- 50 18 40	- 24 53 54	66	5.1	4.8	5.8	72.0	3.1	46.0	16.0	106.5	51.0
38	- 50 18 07	- 24 53 45	66	4.6	4.5	11.8	34.0	2.4	38.0	12.0	132.2	56.0
49	- 50 18 43	- 24 53 19	53	5.5	4.4	20.2	121.0	1.5	35.0	11.0	124.1	42.0
69	- 50 18 29	- 24 53 17	74	5.2	4.9	3.4	64.0	2.1	42.0	12.0	99.6	36.0
78	- 50 18 39	- 24 53 05	62	4.8	5.0	1.7	52.0	2.5	42.0	12.0	108.5	52.0
102	- 50 18 40	- 24 52 34	73	5.4	4.9	2.7	58.0	4.0	54.0	14.0	130.0	55.0

FIGURA 4.2 - Disposição das amostras georreferenciadas, exemplificando alguns dos atributos numéricos das propriedades químicas do solo, apresentadas por ponto.

Os valores associados à cada amostra, dispostos conforme mostra a Figura 4.2, são apresentados no Apêndice B e totalizam 106 pontos, os quais foram utilizados na modelagem. Dentre estes, o modelo de NC, que foi apresentado no item 4.2.2.1 deste capítulo, utiliza as variáveis V% e CTC.

O posicionamento geográfico das amostras foi executado utilizando-se receptores GPS (Global Positioning System), o que garante o georreferenciamento preciso das mesmas. No SIG estas amostras têm a elas associadas seus atributos numéricos, como as concentrações de V% e CTC e são armazenadas na forma de banco de dados, para cada talhão, conforme é exemplificado na Figura 4.2.

A medição da produção das culturas foi obtida a partir de equipamentos instalados nas colheitadeiras, que medem o volume de grãos colhidos (trigo, soja, milho etc). Este

volume é posicionado através dos receptores GPS e, assim, também esses dados têm a eles associados o posicionamento geográfico.

A Fazenda Figueira adotou em 2001 o programa de agricultura de precisão proposto e conduzido pela empresa IMPAR (2005) e que prevê a utilização progressiva do sistema de plantio direto rotacionado, ou seja, este sistema de manejo vai sendo implementado nos talhões da fazenda aos poucos, em ciclos de três anos. Após a inclusão do talhão no sistema, este passa a ter um controle dos níveis de fertilidade do solo e produção das culturas instaladas no campo.

A área da fazenda foi subdividida em talhões onde a implantação do sistema é progressiva e a rotação das culturas é programada da seguinte forma:

- No primeiro ano, planta-se o milho, no verão; aveia, trigo ou cevada no inverno;
- No segundo e terceiro anos, planta-se soja, intercalando, também, com as culturas de inverno citadas acima.

Antes do primeiro plantio de inverno, para os talhões que estão entrando no referido programa, ou após a colheita do terceiro ano do plantio de verão, para os talhões que já estão no programa, é realizada a amostragem do solo. No processo de amostragem são coletadas todas as informações necessárias para o estudo da correção do solo, no que diz respeito à calagem e adubação.

Segundo dados da empresa IMPAR (2005), alguns fatores que afetam a produção das culturas são controlados com mais facilidade, auxiliando o trabalho do planejador para intervenção. A Figura 4.3 mostra graficamente a probabilidade das causas de variabilidade na produção (eixo X) e a facilidade de intervenção nestas causas, por parte do produtor ou tomador de decisão (eixo Y). Circundados por uma elipse aparecem em destaque os fatores que causam maior variabilidade na produção e que, ao mesmo tempo, apresentam maior facilidade de intervenção ou controle.

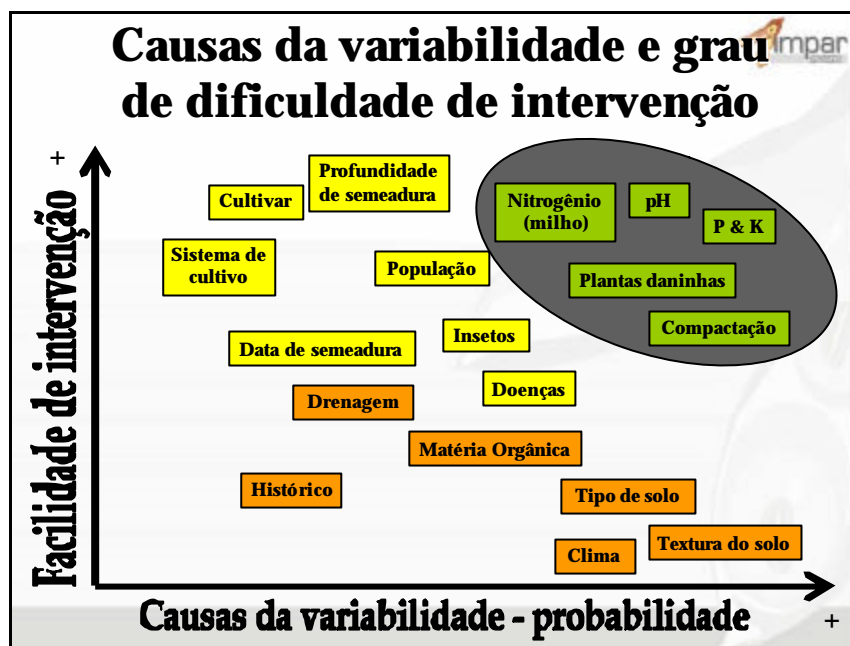


FIGURA 4.3 - Causas de variabilidade na produção e facilidades de intervenção.

Fonte: IMPAR (2005)

Dentre estes fatores destacados na elipse da Figura 4.3, observa-se que o pH causa grande variabilidade na produção, mas é de fácil controle. O pH é um indicador de acidez no solo que está relacionado à necessidade de calagem. Este fator justifica, em parte, a escolha do modelo de NC, para o estudo de caso. Trata-se de um modelo composto por variáveis facilmente controladas e amplamente amostradas na área da fazenda Figueira. A aplicação de calcário tem sido sugerida (McBRATNEY et al., 1997; VISCARRA ROSSEL e McBRATNEY, 2001) como uma prática eficiente para manter um pH aceitável no crescimento de uma variedade de culturas.

4.3 Modelagem Espacial para Construção de Cenários de Risco

Neste item são apresentados e discutidos os resultados da modelagem espacial para necessidade de calcário e os cenários de risco gerados, segundo os procedimentos abordados no capítulo 3.

4.3.1 Correlação entre as Variáveis

Definido o modelo para o cálculo da NC e o conjunto de amostras a ser utilizado, a correlação entre as variáveis foi verificada. O grau de relacionamento linear entre as

variáveis CTC e V_1 é mostrado no valor do coeficiente de determinação, r_{CTC,V_1} . Segundo Neter et al. (1996) o coeficiente de determinação é estimado pelo coeficiente de correlação entre as amostras, r . O valor do coeficiente de correlação entre CTC e V_1 calculado é $r=0.7$, significativo a 5%.

Considera-se importante decidir se esta correlação determinada é verdadeira ou não. Para tanto, utiliza-se um teste de hipótese do coeficiente de correlação. A regra de decisão segue a distribuição t-student com $(n-2)$ graus de liberdade.

4.3.2 Transformação em Principais Componentes

Após verificar a existência de correlação entre as variáveis do modelo de NC, o método das principais componentes (PC) foi aplicado sobre CTC e V%. Este procedimento visa decorrelacionar as mesmas antes de efetuar a simulação.

A transformação das PC foi efetuada sobre os vetores com os pontos amostrados de CTC e V%, diretamente do solo, constituindo um novo sistema de coordenadas, no espaço das PC. Supondo que os vetores que descrevem os pontos, no novo sistema de coordenadas, são representados por y , então, é necessário definir uma transformação linear, aqui denominada T , das coordenadas originais, representadas por x , tal qual a Equação 4.3. Seguindo a abordagem apresentada em Richards (1993), existe a restrição de que a matriz de covariância dos dados no espaço y , Σ_y , deve ser diagonal, o que implica que nos elementos fora da diagonal a correlação é zero.

$$[y]=[T][x] \quad (4.3)$$

Todo o procedimento para a construção da matriz de transformação T está apresentado em Richards (1993) e a seqüência efetuada pelo autor foi executada em planilha eletrônica, para o conjunto de dados deste estudo de caso. Por se tratar de duas variáveis, CTC e V%, duas PC são geradas: PC_1 e PC_2 . Os resultados desta operação compõem dois conjuntos de valores, para PC_1 e PC_2 e estão no Apêndice C.

De acordo com o que foi apresentado no capítulo 3 é possível checar se a ortogonalidade das principais componentes, o que as torna espacialmente independentes, duas a duas em $h=0$, se estende para os outros vetores de separação, $h \neq 0$, através de um correlograma cruzado. A Figura 4.4 apresenta o correlograma cruzado entre PC_1 e PC_2 e como pode ser constatado a correlação entre elas fica em torno de zero, atingindo um máximo de 0.3. Segundo Pérez e Journel (1991) e Goovaerts (1997), esse valor de correlação pode ser considerado aceitável para as distâncias $h \neq 0$ e para a aplicação do método. Deste modo, a próxima etapa refere-se à Simulação Sequencial Condicionada por Indicação das PC, ou seja, PC_1 e PC_2 .

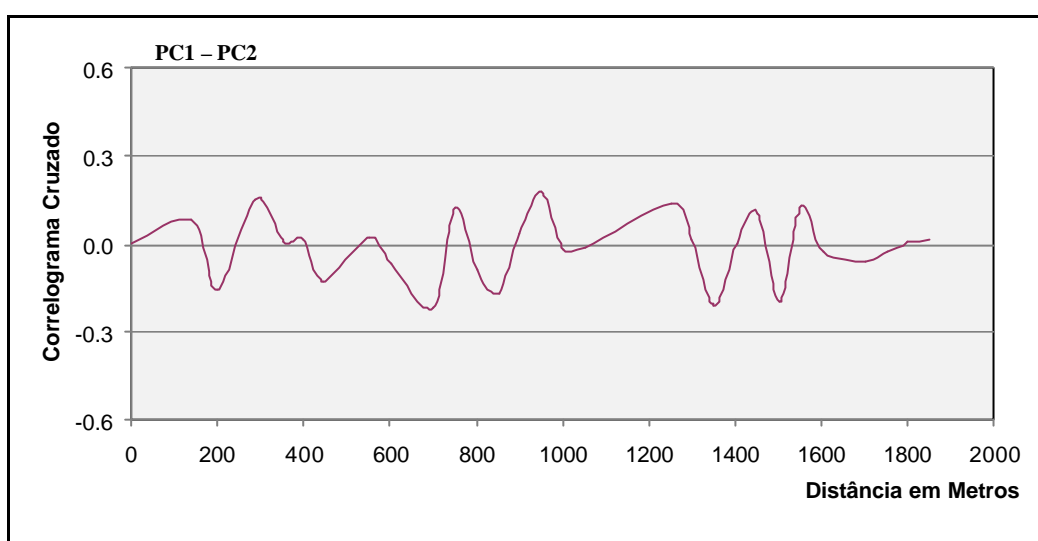


FIGURA 4.4 - Correlograma Cruzado de PC_1 e PC_2 .

O procedimento da simulação sequencial condicionada por indicação está fundamentado teoricamente no capítulo 2 e, neste trabalho, apresenta para os resultados gerados, a estrutura de grades regulares, ou de campos numéricos definida em Câmara (1995), como padrão de representação.

Utilizou-se um programa para executar simulação sequencial por indicação, da biblioteca da GSLIB (DEUTSCH e JOURNAL, 1998), na versão 2.0 com 400 realizações, conforme capítulo 3.

A simulação gera um conjunto de imagens equiprováveis, ou igualmente representativas, de cada VA. Tomando o conjunto de imagens simuladas, tem-se, para cada localização u , da representação da grade regular, conforme ilustra a Figura 4.5, um

conjunto de valores simulados da primeira e da segunda principal componente (PC_1 e PC_2). A partir deste conjunto, a função de distribuição acumulada de PC_1 e PC_2 é estabelecida.

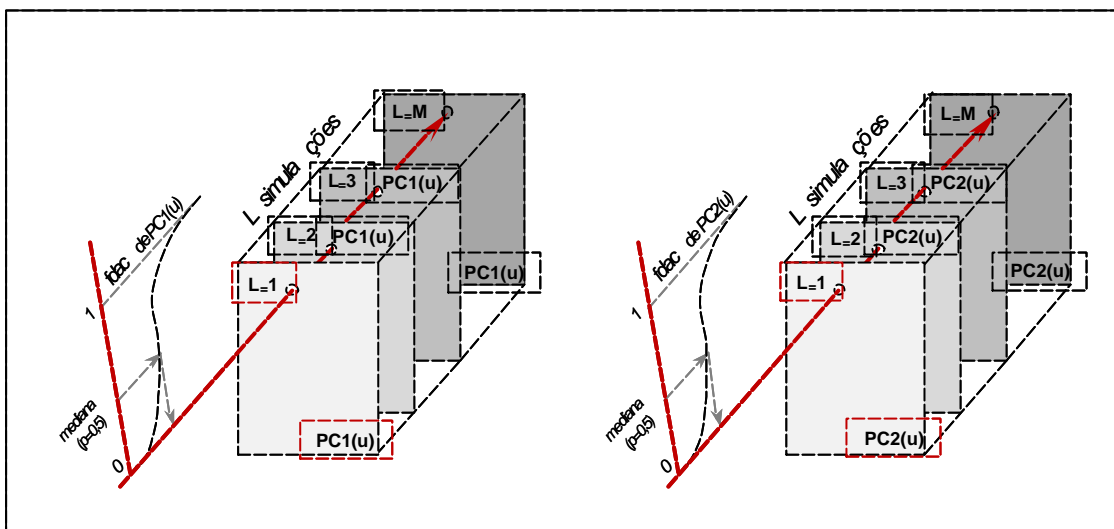


FIGURA 4.5 - Ilustração das simulações de PC_1 e PC_2 e respectivas construções de suas fdac.

Na realização do processo de simulação seqüencial por indicação, o conjunto amostral de cada variável PC_1 e PC_2 foi transformado por indicação, definindo-se novos conjuntos de amostras de variáveis binárias, segundo valores de corte estabelecidos previamente. Os valores de corte foram determinados para cada uma das PC, gerando-se três novos conjuntos por indicação, definidos em quantis (q): $q_{5\%}$ ou $(q_{0,25})$, $q_{50\%}$ ou $(q_{0,5}$, mediana) e $q_{75\%}$ ou $(q_{0,75})$.

Posteriormente, para cada um dos conjuntos por indicação, foi efetuada a análise de variografia, que definiu os parâmetros dos modelos de semivariogramas teóricos, ajustados, em seguida, aos modelos experimentais, conforme procedimento da geoestatística documentado na literatura, por exemplo, Camargo (1997). A Figura 4.6 apresenta os três variogramas ajustados para PC_1 e os três ajustados para PC_2 . Os parâmetros de ajuste estão apresentados na Tabela 4.1. Esses variogramas definem a estrutura de correlação que representa a variação espacial de cada propriedade química estudada. Os modelos experimentais definidos no ajuste dos variogramas foram exponenciais, refletindo o padrão de continuidade espacial para cada corte.

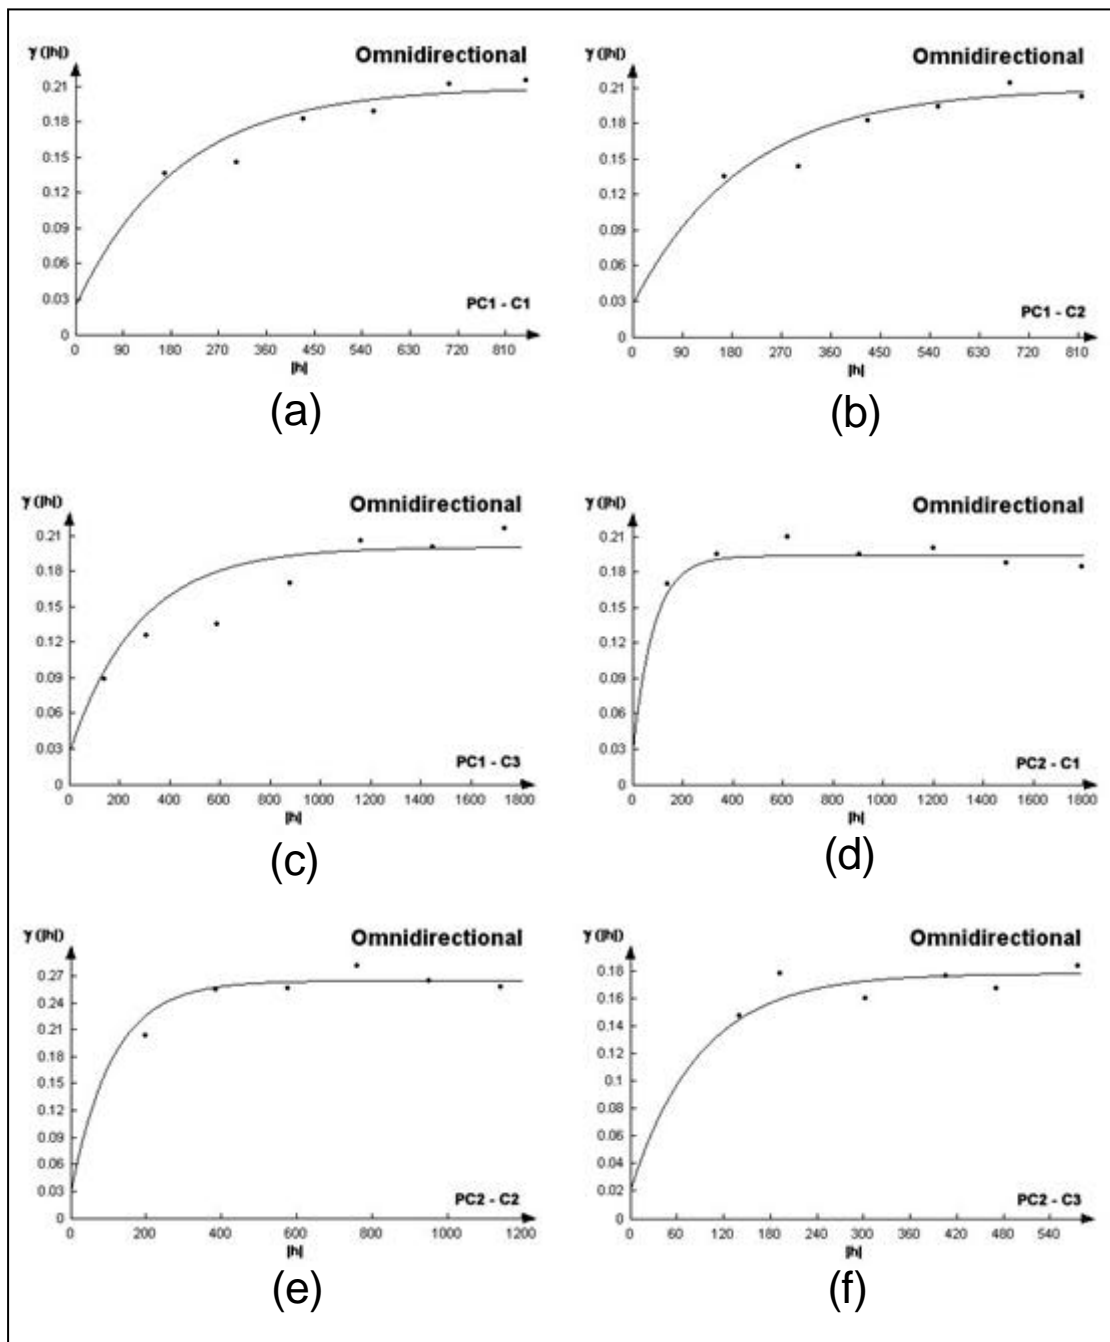


FIGURA 4.6 - Variogramas ajustados para: PC₁, (a) primeiro corte, ($q_{25\%}$)=116.47, (b) segundo corte ($q_{50\%}$)=129.43 e (c) terceiro corte ($q_{75\%}$)=155.97; PC₂, (d) primeiro corte, ($q_{25\%}$)=7.05, (e) segundo corte ($q_{50\%}$)=13.17 e (f) terceiro corte ($q_{75\%}$)=21.39.

TABELA 4.1 - Parâmetros dos semivariogramas de PC₁ e PC₂

Parâmetros		PC ₁	Parâmetros		PC ₂
1º Corte q25% = 116.47	tipo	Exponencial	1º Corte q25% = 7.05	tipo	Exponencial
	efeito pepita (C ₀)	0.025		efeito pepita (C ₀)	0.03
	contribuição (C ₁)	0.19		contribuição (C ₁)	0.16
	alcance (a ₁)	581.25 m		alcance (a ₁)	250.56 m
2º Corte q50% = 129.43	tipo	Exponencial	2º Corte q50% = 13.17	tipo	Exponencial
	efeito pepita (C ₀)	0.03		efeito pepita (C ₀)	0.03
	contribuição (C ₁)	0.18		contribuição (C ₁)	0.23
	alcance (a ₁)	607.42 m		alcance (a ₁)	330.48 m
3º Corte q75% = 155.97	tipo	Exponencial	3º Corte q75% = 21.39	tipo	Exponencial
	efeito pepita (C ₀)	0.03		efeito pepita (C ₀)	0.02
	contribuição (C ₁)	0.17		contribuição (C ₁)	0.16
	alcance (a ₁)	825.18 m		alcance (a ₁)	269.93 m

Seja $Z_i(\mathbf{u})$, $i=1,2$, funções aleatórias, relacionadas às seguintes variáveis, PC₁ e PC₂, e cujos valores observados correspondem a n pontos dos conjuntos amostrais transformados de $z_i(\mathbf{u}_a)$, $i=1,2$ e $a=1,2,\dots,n$, em que z_1 , z_2 são os valores de PC₁ e PC₂. Cada $Z_i(\mathbf{u})$ é representada pelo seu modelo de incerteza espacial, dado pela sua função de probabilidade acumulada conjunta condicionada ao conjunto de (n) dados observados.

4.3.3 Transformação Inversa

A transformação inversa (TI) das PC, necessária para restabelecer a correlação entre as variáveis originais, CTC e V%, foi efetuada invertendo a função T da equação (4.5), como mostra a equação (4.6):

$$[x]=[T]^{-1}[y] \quad (4.6)$$

Após as transformações inversas das PC, cujo procedimento também está apresentado no Apêndice C, foi realizada uma comparação entre a simulação pós-transformada inversa das PC, com a simulação direta das variáveis originais (sem decorrelacioná-las antes), CTC e V%. A Figura 4.7 mostra a comparação para V% e a Figura 4.8 mostra a comparação para CTC. Para comparar visualmente as imagens em níveis de cinza destas figuras, o contraste das imagens foi ampliado, tendo como base as imagens com maior amplitude de níveis de cinza.

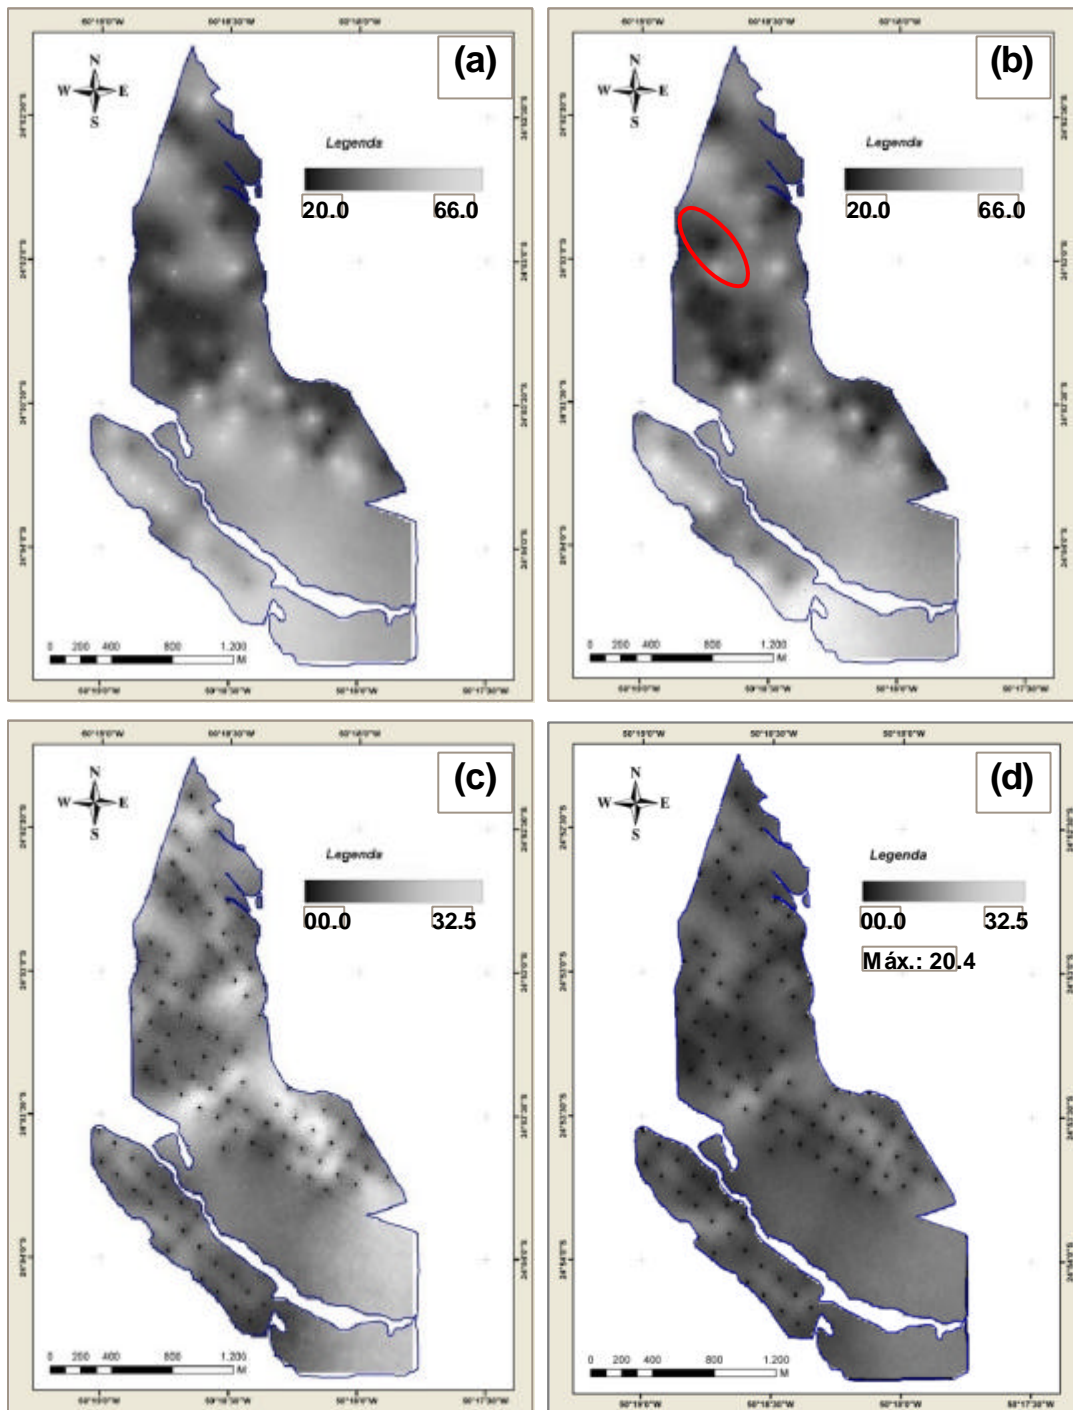


FIGURA 4.7 - Imagens em níveis de cinza da média e desvio padrão simulados para V%: (a) representação das estimativas de V% por média, simulada a partir das amostras originais; (b) representação das estimativas de V%, simulada a partir da PC e com aplicação da transformada inversa; (c) representação dos desvios padrões das simulações da variável original V%; (d) representação dos desvios padrões das simulações da PC com aplicação da transformada inversa.

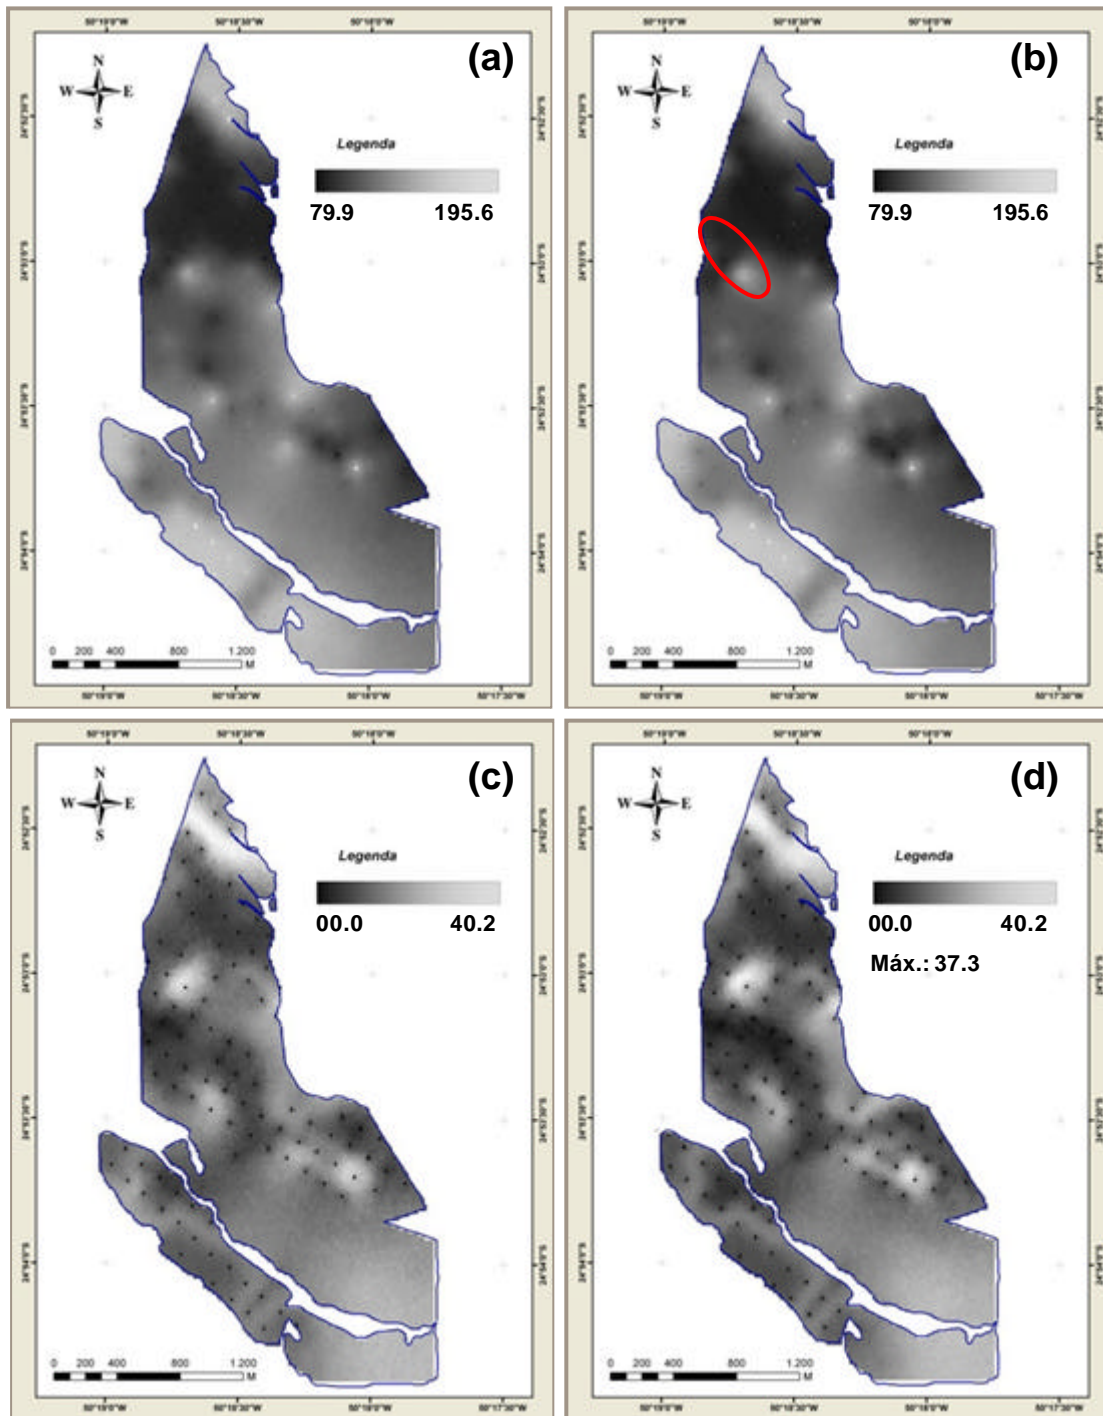


FIGURA 4.8 - Imagens em níveis de cinza da média e desvio padrão simulados para CTC: (a) representação das estimativas de CTC por média, simulada a partir das amostras originais; (b) representação das estimativas de CTC, simulada a partir da PC e com aplicação da transformada inversa; (c) representação dos desvios padrões das simulações da variável original CTC; (d) representação dos desvios padrões das simulações da PC com aplicação da transformada inversa.

Observa-se na Figura 4.7 a e b que não há diferenças visualmente significativas entre as imagens, as quais correspondem à média dos valores simulados para a variável V%, originalmente amostrada no solo, em (a), e após aplicação da transformada inversa, em (b). O mesmo ocorreu para a variável CTC, cujas imagens estão apresentadas na Figura 4.8 (a) e (b). Estas, ao serem comparadas, também não apresentaram, visualmente, mudanças significativas no padrão de continuidade. Os valores de média estão associados à uma escala de níveis de cinza, onde os níveis de cinza mais claros correspondem aos valores de média mais altos e os níveis de cinza mais escuros, aos valores de média mais baixos.

Observa-se, no entanto, que o mesmo comportamento não ocorreu nas imagens de incerteza, representadas pelo desvio padrão. A Figura 4.7 c mostra a incerteza relacionada à simulação dos dados originalmente amostrados de V%; sem decorrelação prévia, pela transformação de PC. A Figura 4.7 d mostra a incerteza relacionada à simulação efetuada sobre os dados decorrelacionados e já passados pela transformação inversa.

Ao compará-las concluiu-se que o valor máximo de desvio padrão na imagem da Figura 4.7 d, com desvio padrão = 20.4, diminuiu em relação à Figura 4.7 c, com desvio padrão = 32.5. O mesmo padrão se repetiu nas imagens de CTC, Figura 4.8 c, com desvio padrão = 37.3, e Figura 4.8 d, com desvio padrão = 40.2.

Ortiz et al. (2007), atribuem o decréscimo da incerteza nas imagens obtidas após a transformada inversa das principais componentes, ao fato de ter adequadamente considerado a correlação entre as variáveis do modelo. Cada variável foi decorrelacionada e simulada independentemente da outra. No entanto, como a correlação entre elas é de fundamental importância no modelo que calcula a NC, ao efetuar a transformada inversa essa correlação foi reconstituída e isso se refletiu em valores menores de incerteza.

Uma observação importante é que ao tratar adequadamente a correlação entre variáveis no processo de modelagem espacial, evita-se que incertezas maiores sejam propagadas

para os valores finais do modelo. Essa observação pode evitar erros relacionados a superestimativas ou subestimativas da variável resultante.

O procedimento adotado é uma solução de contorno simples quando não se dispõe de uma fdac conjunta das variáveis correlacionadas ou mesmo de algoritmos que possibilitem uma simulação condicionada à correlação das variáveis.

4.4 Construção de Cenários de Risco para Tomada de Decisão

Esta seção mostra como a abordagem apresentada até o item 4.3, deste capítulo, pode ser utilizada para a construção de um conjunto de cenários. Estes cenários podem ser utilizados de forma isolada ou complementar, visando trazer para o tomador de decisão, alternativas úteis para serem usadas no planejamento da aplicação de insumos.

Para alcançar os objetivos propostos, foi desenvolvida uma série de programas e interfaces, fora do ambiente SIG, em linguagem C++ e MATLAB, juntamente com a biblioteca de geoestatística GSLIB (DEUTSCH e JOURNAL, 1998) e o Sistema de Processamento de Informações Georreferenciadas – SPRING (CÂMARA et al., 1996), os quais são disponibilizados gratuitamente.

Os resultados foram exportados e, por vezes ainda manipulados, utilizando a linguagem para efetuar álgebra de mapas, LEGAL, do SPRING. Cenários representados por mapas associados a tabelas, considerando a informação da incerteza, risco e custo financeiro foram manipulados para gerar parâmetros que servirão para direcionar o tomador de decisão.

Entretanto, antes de apresentar os resultados da proposta de planejamento para o conjunto de talhões definidos na fazenda Figueira, a abordagem comercial que vem sendo atualmente adotada pela empresa IMPAR para elaborar os mapas de aplicação de insumos, será apresentada. O objetivo, neste caso, é situar o leitor quanto aos procedimentos atualmente utilizados, por uma empresa comercial, como prática na agricultura de precisão.

4.4.1 Uma Abordagem Comercial

O planejamento agrícola desenvolvido pela empresa IMPAR para as áreas onde o sistema de agricultura de precisão já foi implantado, segue uma seqüência de etapas, conforme apresentado no item 4.2.4 deste capítulo e resumido na Figura 4.9, iniciado pela coleta de dados de fertilidade do solo, histórico de pragas, histórico climático e a própria produção histórica da cultura na área em questão.

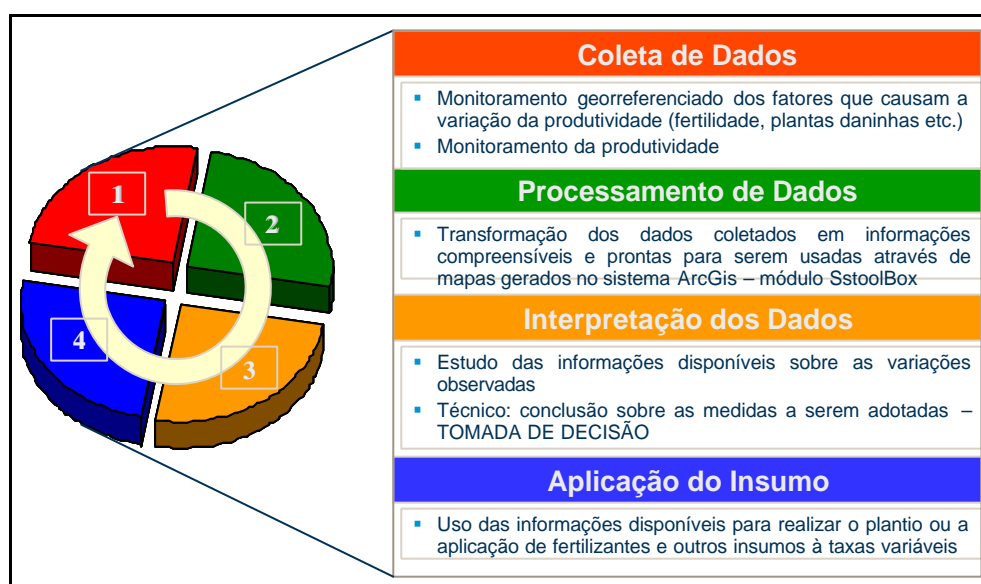


FIGURA 4.9 - Etapas utilizadas no planejamento da agricultura de precisão.

Esta primeira etapa tem o objetivo de identificar a variabilidade existente em campo dos diversos fatores que influenciam na produção. Sendo que parte deles será utilizada como fonte de informação auxiliar no processo decisório. Já os dados de fertilidade e de produção são espacializados através da utilização do ArcGis e tratados estatisticamente utilizando um módulo específico, o SstoolBox.

A segunda etapa consiste no processamento dos dados coletados para avaliar e quantificar a variabilidade medida e, então, buscar relacionar a variabilidade da produção com os fatores que influenciam a mesma.

Já na terceira etapa é realizada a interpretação dos dados visando propor estratégias de gerenciamento agrícola que levem em conta o cenário de variabilidade apresentado. Esse trabalho conduz ao planejamento de ações que, em geral, são consolidadas na

forma de mapas de aplicação de insumos, finalizando na quarta etapa, que se resume na execução do plano de plantio.

A vantagem dessa abordagem é que o cálculo de sementes, adubo, calcário, herbicida e inseticida, não são efetuados pela média. O agricultor vai aplicar apenas a quantidade necessária para cada zona, de acordo com as exigências apontadas pelos mapas. Se ganha, assim, em tempo e financeiramente. Sem contar no benefício ambiental, o qual não é escopo deste trabalho.

O SIG vem sendo utilizado para gerar representações contínuas dos atributos do solo amostrados, ou seja, os mapas. Os mapas que são gerados a partir de conjuntos de amostras de campo são elaborados utilizando o procedimento geoestatístico de krigagem ordinária ou simples. Mais detalhes sobre esses métodos podem ser encontrados em literatura disponível sobre o assunto, entre eles, Deutsch e Journel (1998), Felgueiras (1999).

O procedimento para gerar o mapa de aplicação de calcário, que define o experimento deste trabalho, foi efetuado primeiramente de modo a reproduzir a abordagem comercial em agricultura de precisão. Este resultado é apresentado na Figura 4.10 abaixo e reproduz o mesmo mapa que pode ser gerado por um técnico da IMPAR, com legenda fracionada em t/ha, sugerida pelos técnicos da empresa. O modelo para cálculo da NC é o mesmo definido na Equação (4.2) e o procedimento de espacialização usado foi a krigagem ordinária, e os resultados indicam a quantidade de calcário a ser colocada nas áreas delimitadas.

A Figura 4.10 ilustra o resultado de uma classificação por faixas, aqui referenciada por fatiamento, da representação das médias da NC, definida em 5 classes sugeridas pela IMPAR, considerando-se a seguinte escala de valores conforme apresentada na Tabela 4.2. As demais análises que serão apresentadas também seguirão esta tabela.

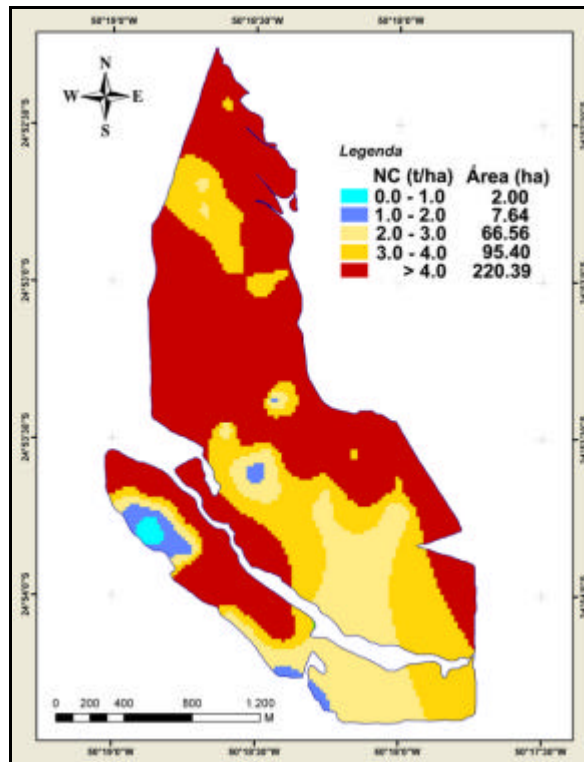


FIGURA 4.10 - Mapa obtido por procedimento de krigagem ordinária e que representa as quantidades de calcário a serem colocadas nas áreas indicadas, segundo as faixas definidas na legenda.

TABELA 4.2 - Escala de valores para representar a necessidade de calcário.

NECESSIDADE DE CALCARIO	
MUITO BAIXA	0 - 1 t/ha
BAIXA	1 - 2 t/ha
MÉDIA	2 - 3 t/ha
ALTA	3 - 4 t/ha
MUITO ALTA	> 4 t/ha

4.4.2 Alternativas Propostas

A seguir será apresentada uma seqüência de procedimentos que resultaram em diferentes cenários que levaram em consideração os modelos geoestatísticos de incerteza e risco. Esses cenários, representados por mapas associados a tabelas, mostram abordagens diferentes da apresentada no item 4.4.1.

A primeira colocação que deve ser feita diz respeito ao procedimento de espacialização adotado: simulação seqüencial condicionada por indicação. A opção da simulação é

fundamentada em alguns aspectos importantes levantados no trabalho de Felgueiras (1999), ao comparar os procedimentos de krigeagem e simulação.

Resumidamente, o procedimento de simulação estocástica permite a geração de um conjunto de campos aleatórios equiprováveis, superfícies que têm características probabilísticas similares, relacionadas a um atributo. Neste procedimento, a função de distribuição de probabilidade, inferida pela krigeagem, para uma determinada localização, é usada para se obter realizações para o valor do atributo. Uma simulação estocástica condicionada combina os dados nas posições observadas, os dados já simulados e a informação do variograma para computar novas realizações para localizações ainda não consideradas. O conjunto de valores realizados, em uma determinada posição possibilita a inferência de estatísticas e incertezas locais a respeito do atributo. O conjunto de campos obtidos pela simulação permite a inferência de estatísticas e incertezas globais a respeito do atributo.

O procedimento de simulação estocástica condicionada seqüencial, pode ser considerado uma ferramenta mais completa do que a krigeagem, pois possibilita inferências baseadas em distribuições conjuntas. A simulação estocástica deve ser usada, em lugar da krigeagem, nas seguintes situações: deseja-se estimar incertezas globais que consideram distribuições conjuntas de variáveis aleatórias dependentes (SRIVASTAWA, 1990 e FELGUEIRAS, 1999).

A modelagem espacial em SIG considera vários campos equiprováveis, de um ou mais atributos, para serem utilizados em modelagens computacionais e procedimentos de propagação de incertezas, como por exemplo, para a simulação de Monte Carlo. Primeiro um conjunto de imagens igualmente representativas da $NC(\mathbf{u})$ é gerado por simulação. Tomando o conjunto destas imagens simuladas, tem-se, para cada localização \mathbf{u} da representação da grade regular, conforme ilustra a Figura 3.3, um conjunto de valores simulados $nc(\mathbf{u})$ da VA $NC(\mathbf{u})$. A partir deste conjunto, a função de distribuição acumulada da $NC(\mathbf{u})$ é estabelecida, possibilitando o cálculo de vários valores de cortes e, posteriormente, a construção de cenários.

O SIG SPRING pode ser utilizado para executar diretamente modelos computacionais simples através de operações básicas, lógicas e aritméticas contidas nos seus módulos de análise ou de álgebra de dados espaciais. Neste trabalho, por se tratar de um modelo com muitas realizações de simulação, a opção foi desenvolver um programa para ser executado fora do ambiente do SIG, porém com a estrutura de representação voltada para o SPRING. O SPRING foi usado como base de armazenamento de dados espaciais e também como ferramenta de visualização para os dados de entrada e de saída do modelo. Aqui, a opção metodológica foi criar uma interface externa entre o SIG e o sistema de modelagem.

4.4.2.1 Estimadores Ótimos, Simulação de Monte Carlo e Propagação de Incertezas – Primeira Alternativa

Este item apresenta o mapa de NC, equivalente ao apresentado na abordagem comercial (item 4.4.1), porém, resultado do procedimento de simulação. Constitui a etapa de integração das variáveis de entrada do modelo, simuladas sequencialmente pelo método da geoestatística por indicação, que gerou os campos numéricos de V% e CTC. A etapa de modelagem, propriamente a integração dos campos simulados de V% e CTC, foi efetuada fora do ambiente SIG, através de um aplicativo desenvolvido para efetuar a simulação de Monte Carlo. Cada VA foi representada por 400 campos numéricos (grades regulares). A simulação de Monte Carlo foi executada com 400 realizações sobre os 400 campos de cada variável de entrada do modelo de NC. A função g , apresentada no capítulo 3, neste trabalho representada pelo modelo de NC, definido na equação (4.2), foi aplicada, seguindo um sorteio aleatório das realizações de cada um dos 400 campos numéricos de entrada e que resultaram em 400 campos numéricos da variável resultante, $NC(\mathbf{u})$ (vide Figura 3.3, capítulo 3). O resultado foi estruturado para ser visualizado no ambiente do SPRING.

A seguir serão apresentados mapas para planejamento da aplicação do calcário seguindo a abordagem da simulação, para alguns estimadores ótimos diferentes.

a) Estimador Ótimo da Média

O conjunto de realizações da VA resultante, $NC(\mathbf{u})$, possibilita a obtenção de mapas através de estimadores ótimos. A Figura 4.11 apresenta o resultado da modelagem de NC, segundo o estimador ótimo da média, equivalente ao adotado na abordagem comercial apresentada no item 4.4.1. Mostra, também, as incertezas associadas às estimativas, representadas pelo desvio padrão.

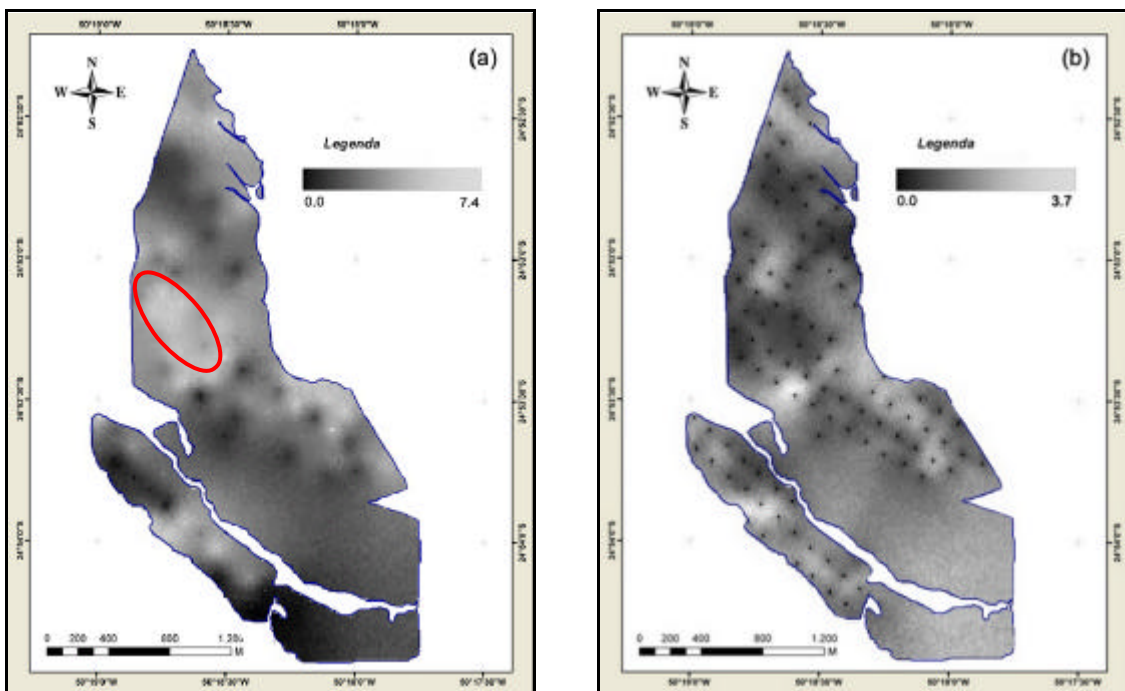


FIGURA 4.11 - (a) Mapa resultante da modelagem de NC, segundo estimador média; (b) Mapa de incertezas propagadas da modelagem de NC, representadas pelo desvio padrão.

As imagens das Figuras 4.7 (b) e 4.8 (b) mostram a coerência do resultado da modelagem de NC, na Figura 4.11 (a): Localizações com baixos valores de V% e CTC médio/altos, marcadas com uma elipse em vermelho nas três Figuras citadas, indicam maiores necessidades de calcário (de médio para alto); ou seja, a acidez do solo naquelas localizações não está controlada e, portanto, o solo está precisando de correção com calcário.

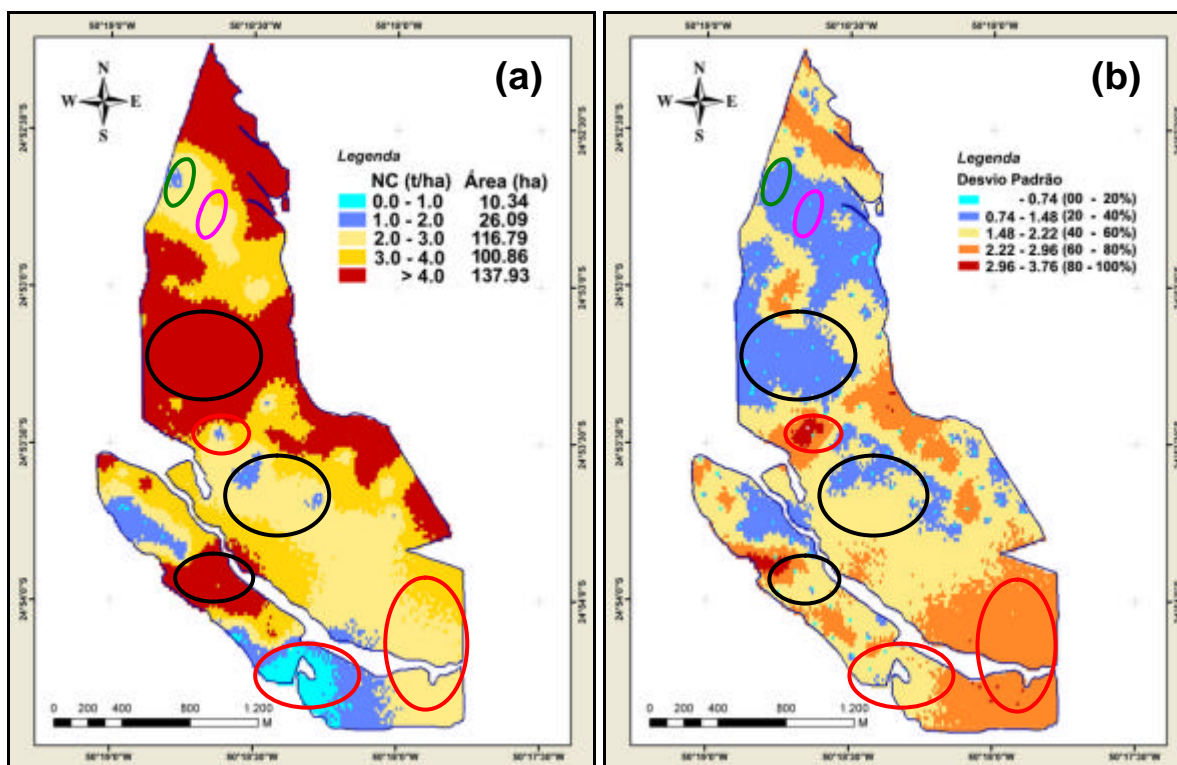


FIGURA 4.12 - (a) Mapa de média dos campos simulados e (b) Mapa de incertezas, representadas pelo desvio padrão.

Estes mapas podem ser apresentados em classes temáticas, como na Figura 4.12, onde a quantidade de NC é representada por faixas de aplicação: (a) indicando as quantidades de calcário que devem ser aplicadas no solo e a suas respectivas áreas e (b) incertezas associadas ao desvio padrão; neste caso, porcentagens foram associadas às faixas de desvio padrão, com intuito de facilitar a compreensão, normalizando os valores entre 0 e 100%. No entanto, deve ficar claro que esses valores não se referem a medidas de probabilidade e da mesma forma que foi apresentada na Tabela 4.2, pode ser realizada a equiparação qualitativa desta legenda conforme a tabela a seguir:

TABELA 4.3 - Escala de valores para representar a incerteza no cálculo da estimativa de calcário.

AMPLITUDE DA INCERTEZA ASSOCIADA À %	
MUITO BAIXA	00 - 20%
BAIXA	20 - 40%
MÉDIA	40 - 60%
ALTA	60 - 80%
MUITO ALTA	80 - 100%

Um das vantagens da abordagem analisada é a possibilidade de apresentar ao planejador o mapa de incerteza associado ao mapa de estimativas. No caso da simulação, a modelagem da incerteza é gerada por múltiplas realizações, que reproduzem as estatísticas das amostras e tendem com isso, conforme a literatura (SRIVASTAWA, 1989 e GOOVAERTS, 1997), à melhor representar a variabilidade do dado.

Para orientar o trabalho do planejador e otimizar a aplicação de recursos disponíveis, segue uma proposta de ações ordenada por prioridade em função das incertezas:

1. Se ocupar das áreas que indicam menor NC com incertezas baixas;
2. Se ocupar das áreas com NC média, porém, ainda com incertezas baixas;
3. Se ocupar das áreas com NC alta, porém, ainda com incertezas baixas;
4. Se ocupar das áreas com incertezas altas.

O planejador, utilizando a seqüência acima para analisar os mapas da Figura 4.12, verifica a ocorrência de áreas que se enquadram na etapa (1). Estas áreas estão demarcadas, na Figura 4.12, com elipses verdes. Na seqüência, demarcadas com elipses vermelhas, o planejador pode constatar as áreas definidas na etapa (2). Já as áreas com elipses lilás na etapa (3). As demais áreas pertencem à etapa (4), destacadas com elipses pretas.

Sob o ponto de vista do planejamento, para minimizar gastos financeiros, as áreas definidas pela etapa (1) são as mais interessantes. Entretanto, neste experimento, poucas se enquadram nesta condição, o que deve conduzir o planejador a analisar as áreas definidas pelos critérios da etapa (2 e 3). As demais áreas se enquadram nas condições da etapa (4) e, devem merecer especial atenção devido às altas incertezas.

Com estas informações disponíveis o planejador pode definir uma estratégia de ação, como por exemplo: aplicar calcário nas áreas delimitadas nas etapas (1), (2) e (3) e verificar se nas áreas da etapa (4), há necessidade de agregar novas informações, por

exemplo, realizando um adensamento amostral ou até mesmo uma nova amostragem nestas áreas.

Para qualquer uma das opções acima, o planejador deve considerar a quantidade de recursos e o prazo disponível para realização do plantio, em função do retorno financeiro esperado.

Este mapa mostra que, em relação à abordagem comercial apresentada, a associação de incerteza às estimativas, auxilia o planejador na estruturação do planejamento com maior confiabilidade.

A simulação seqüencial condicionada foi, portanto, utilizada para gerar os mapas com indicação das quantidades de calcário que devem ser colocadas, usando o estimador ótimo da média. Esta indicação, assim como no mapa apresentado na abordagem comercial, foi definida em faixas, com quantidades variáveis de insumo. No entanto, de acordo com a metodologia apresentada no capítulo 3, é importante considerar estimadores adequados ao problema em questão, os quais podem subestimar ou superestimar os valores quantificados. Estes estimadores não necessariamente devem ter seus erros minimizados pelo método dos mínimos quadrados, como é o caso da krigagem, ou estimador da média.

Propõe-se a seguir, outra abordagem, onde os erros decorrentes da estimativa da NC no solo, que são subestimar (estimar um valor menor do que seria o valor real) ou, superestimar (estimar um valor maior do que seria o real), devem ser considerados. Esses erros podem produzir efeitos diferentes no processo de produção de uma determinada cultura e, desse modo, alguns estimadores ótimos serão considerados.

b) Estimadores Ótimos dos Quantis

Ao considerar que o efeito de superestimar um valor, deve ser diferenciado do impacto de subestimar, essas diferenças podem ser minimizadas no processo de inferência em função do problema que está sendo analisado.

Neste caso, o planejador pode avaliar se subestimar a NC traz conseqüências indesejadas financeiramente, por exemplo; ou, se o contrário, superestimar a NC é que traz algum tipo de prejuízo neste sentido. O erro de superestimar leva a repor nutrientes onde não é necessário e, subestimar pode conduzir a não repor os nutrientes onde há deficiência e, portanto, prejudicar a produção. Assim, nesse caso, esses erros não devem ser tratados como se tivessem o mesmo impacto. A minimização de um ou de outro, vai depender dos objetivos do trabalho a ser executado, ou seja, a adequabilidade de uma estimativa depende do uso que se pretende fazer desta estimativa.

A literatura sobre aplicação de calcário e aumento de produção de grãos como, Caires et al. (2003), Miranda et al. (2005) e Korndorfen (2005), tem sugerido que doses adequadas de calcário promovem aumento na produção de grãos de soja, milho e trigo. Assim, seguindo também orientação técnica da empresa IMPAR, este experimento parte da premissa que superestimar as doses de calcário traz conseqüências menos impactantes na produção.

Considera-se que o risco de comprometimento da produção é motivado pelos erros de subestimar. Optou-se, portanto, neste experimento, em estimar NC de forma a reduzir este risco. A estimativa que minimiza este erro é dada (ver capítulos 2 e 3) pelo quantil superior à mediana.

Deste modo, reportando a equação (2.19) que define o estimador do quantil- p , $p = \frac{w_2}{w_2 + w_1}$, onde: os parâmetros w_1 (subestimar) e w_2 (superestimar) são não negativos e medem o relativo impacto de subestimar e superestimar a NC, respectivamente.

Deste modo, se $w_1=1$ e $w_2=2$, $p = \frac{2}{2+1} = 0.66 \cong 0.7 = 70\%$.

Assim, os mapas gerados para representar a NC, neste experimento, buscam minimizar o erro de subestimar e, portanto, o estimador do quantil superior à mediana, quantil 0.7, ou $q_{70\%}$, foi adotado. A Figura 4.13 (a) mostra o mapa de NC, em níveis de cinza,

gerado pelo estimador $q_{70\%}$. Os tons de cinza mais claros indicam valores de NC maiores e os mais escuros, valores de NC menores. Observa-se que, neste caso, do quantil superior, o valor mínimo de $nc(u)$ é 0.6 t/ha e não 0 (zero), como para o estimador da média. O que está coerente com a teoria, como Goovaerts (1997) e Cruz (2000): que sugerem minimizar o erro de subestimar.

As incertezas propagadas estão representadas na Figura 4.13 (b), através do mapa de intervalos de quantis ($q_{.95}$ - $q_{.45}$). O intervalo de quantis é uma medida de variabilidade que fornece a diferença entre o maior valor e o menor valor dos atributos. Na amplitude interquantil, a diferença representada é a de dois quantis simétricos em relação ao estimador utilizado. Este tipo de medida de variabilidade deriva diretamente da fdac inferida e tem sido usada como medida de incerteza (FELGUEIRAS, 1999; AGUMYA e HUNTER; 2002).

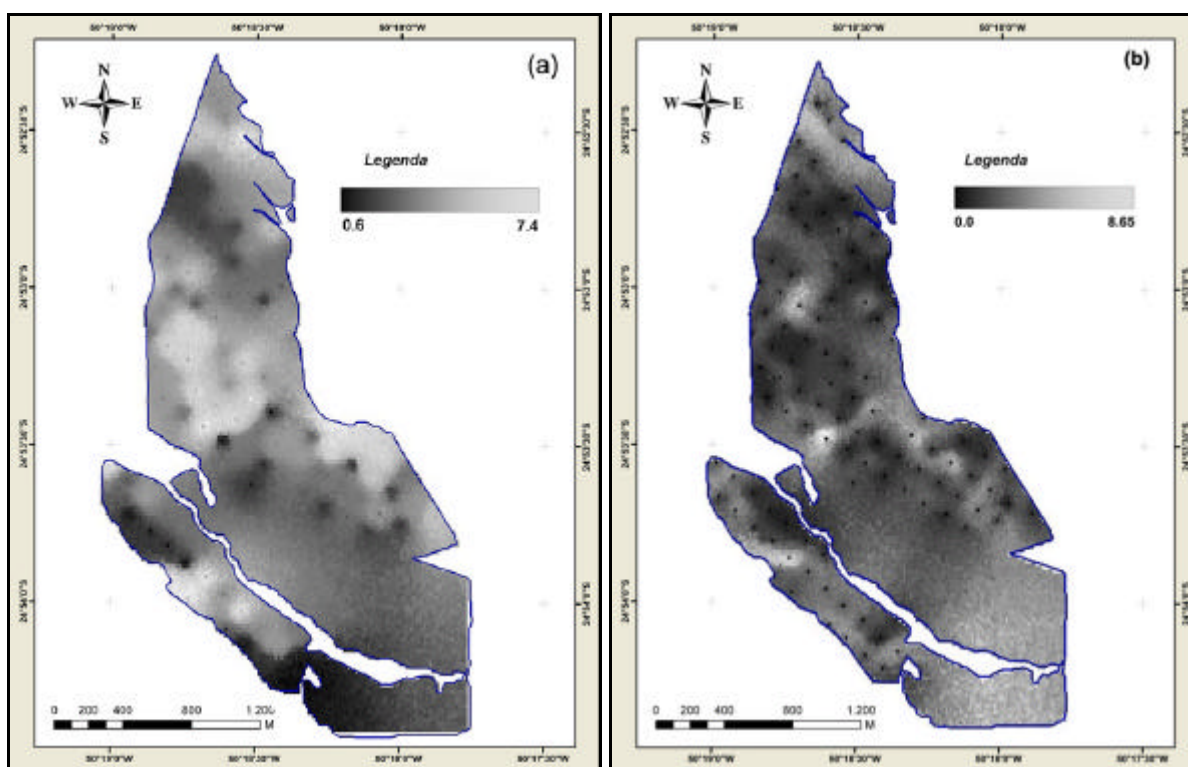


FIGURA 4.13 - (a) Mapa resultante da modelagem de NC, segundo estimador $q_{0.7}$; (b) Mapa de incertezas propagadas da modelagem de NC, representadas pelo intervalo de quantis ($q_{.95}$ - $q_{.45}$).

Como nos mapas anteriores, apresentados em níveis de cinza, por meio da escala de cinza, que tem mínimo em 0.0 e máximo em 8.65, (mapa da Figura 4.13(b)), pode-se constatar a variação da incerteza propagada na modelagem espacial da NC. Os tons mais escuros estão associados às incertezas mais baixas e os mais claros às incertezas mais altas.

Se o tomador de decisão tiver em mãos os mapas apresentados na Figura 4.13, analogamente aos mapas da Figura 4.12, torna-se possível traçar metas para a aplicação de calcário. Pode-se dividir a área em faixas de necessidade de calcário por tonelada; neste caso, porém, com um estimador, considerado mais adequado para o problema de aplicação de calcário, ($q_{70\%}$).

Uma operação de fatiamento no mapa da Figura 4.13(a) resulta em um mapa com cinco classes. A Figura 4.14(a), as faixas foram associadas a cores, procurando associar cores mais fortes às localizações do mapa que estão com maior exigência de insumo. O mesmo pode ser feito para o mapa de incertezas, como mostra a Figura 4.14(b).

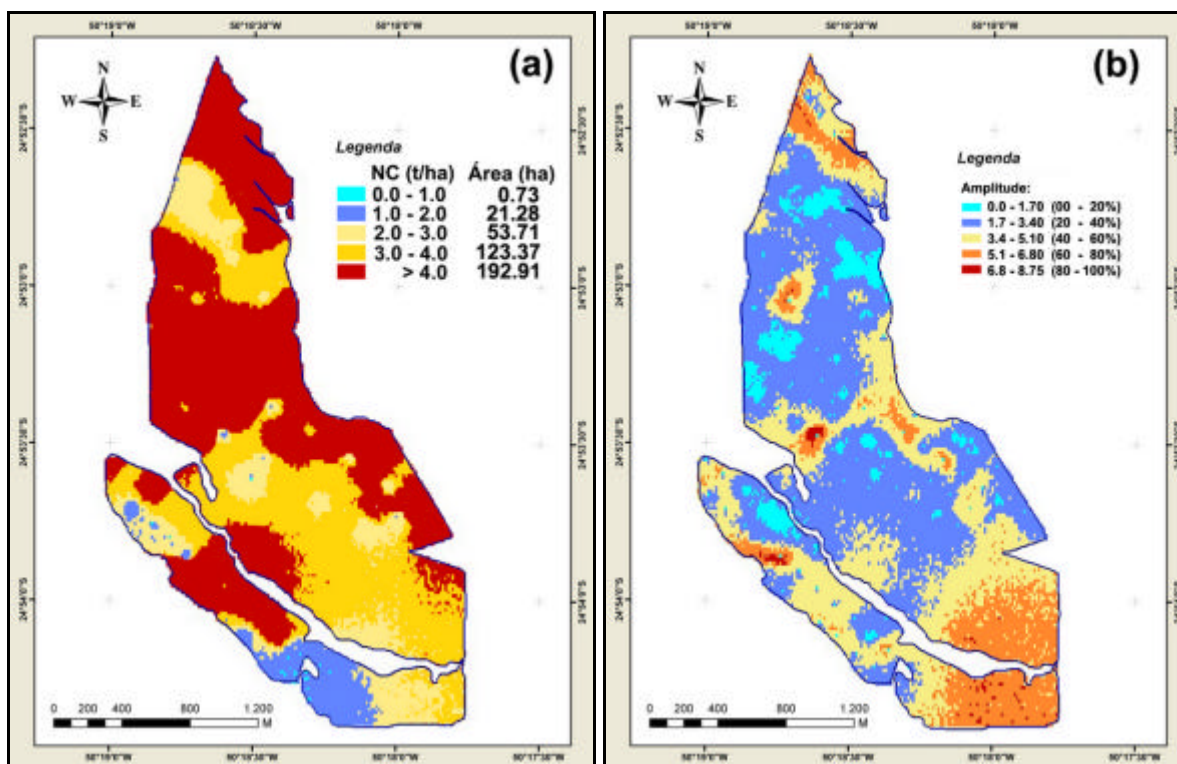


FIGURA 4.14 - (a) Mapa fatiado de NC gerado pelo estimador $q_{70\%}$ e (b) Mapa fatiado de incertezas, geradas pelo intervalo de quantis ($q_{.95}$ - $q_{.45}$).

Embora o estimador $q_{70\%}$, já esteja definido para ser utilizado, diante da premissa de minimizar o erro de subestimar NC, apresentam-se outras possibilidades de escolha para o planejador. A Figura 4.15 apresenta mapas com estimadores ótimos diferentes: quantil inferior, $q_{25\%}$, e mediana, $q_{50\%}$. Nestes mapas a medida de incerteza também pode ser dada pelo intervalo de quantis. Observa-se que o estimador do quantil inferior gera mais áreas indicando menores quantidades de calcário, representadas no mapa pelas cores rosa, cyan e azul. É o que ocorre quando o erro de subestimar é considerado menos relevante diante do problema em mãos.

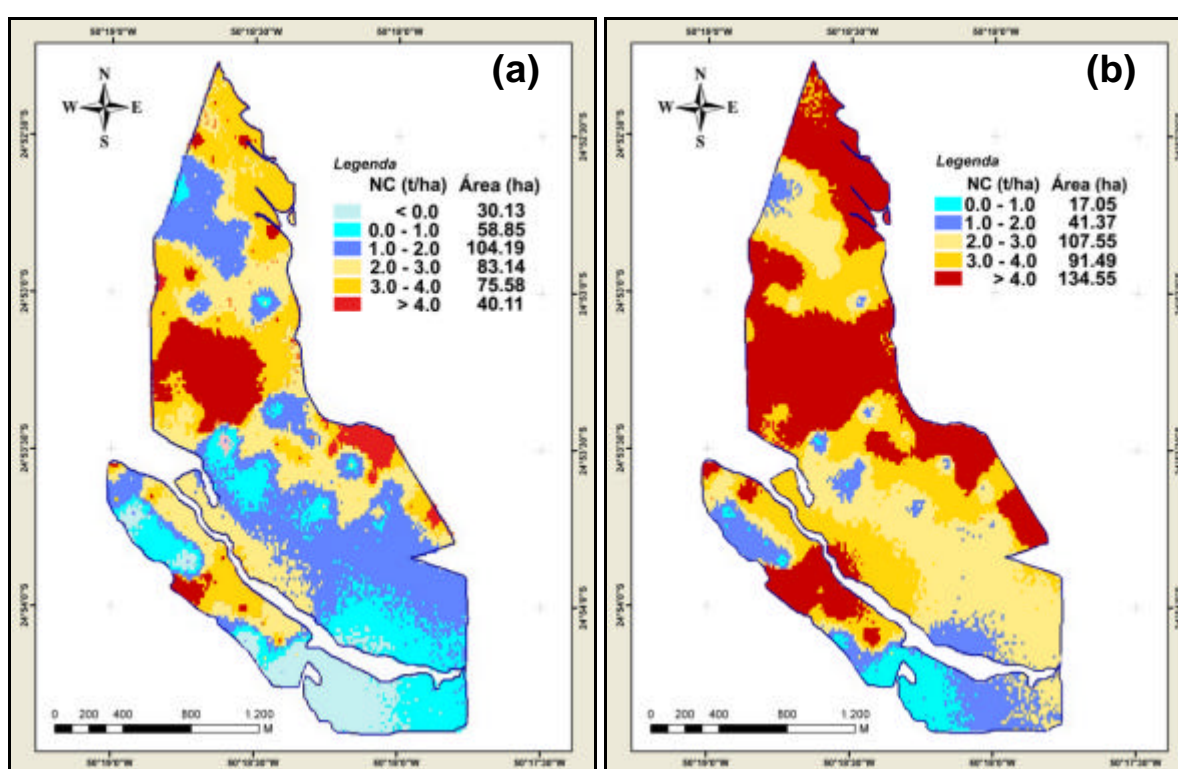


FIGURA 4.15 - Mapas com os estimadores ótimos (a) do quantil inferior, $q_{25\%}$ e (b) mediana, $q_{50\%}$.

No caso do mapa obtido com estimador $q_{70\%}$ (Figura 4.14(a)), observa-se que as áreas com indicações de doses de calcário elevadas, representadas pelas cores laranja e vermelho, são maiores em relação aos mapas obtidos com estimados da Figura 4.15. Seguindo as dosagens estimadas mostradas no mapa (Figura 4.14(a)), neste mapa, deve-se interpretar que o erro de subestimar foi minimizado e, portanto, mais áreas foram incluídas com NC.

Seguindo as indicações das dosagens do mapa da Figura 4.15(a) observa-se que o valor mínimo estimado para NC está abaixo de 0t/ha. Ou seja, há indícios que nestas localizações está ocorrendo um excedente de calcário, e que, portanto, não há necessidade de colocar o insumo. É um valor coerente com um estimador que tem a finalidade de minimizar o erro de superestimar. O que o planejador deve ter em mente, como nos casos anteriores, é que o fato de se colocar calcário a menos vai ou não trazer conseqüências adversas à produção, por exemplo.

O estimador da mediana, ao contrário dos dois anteriores, utiliza uma função de minimização de erros que não prioriza subestimar ou superestimar um valor (ver capítulos 2 e 3) e, portanto, deve ser adotada quando os impactos que são provocados por estes erros podem ser equivalentes.

4.4.2.2 Risco a (Falso Positivo) e Risco b (Falso Negativo) – Segunda Alternativa

Assumindo que a estimativa $q_{70\%}$ foi definida para planejar as áreas que necessitam de aplicação de calcário, tal que o valor estimado da NC na posição u , seja maior que 0 t/ha, uma abordagem também relevante, é questionar os riscos de ocorrem falsos positivos, denominados risco α , ou falsos negativos, denominados, risco β . Estes riscos podem ser apresentados ao planejador, como uma informação adicional, além dos mapas com estimativas baseadas no ótimo.

A decisão de colocar ou não calcário no solo conduz o planejador a levantar algumas questões em relação às estimativas, baseadas nos erros de superestimar e subestimar. As questões levantadas na Tabela 4.4, a seguir, têm a finalidade de facilitar o entendimento do planejador sobre as conseqüências de superestimar ou subestimar, em função do seu problema e coloca que a incerteza está sempre presente em qualquer problema. Sob esta óptica pode-se direcionar uma decisão mais coerente. Essa visão sintetizada vai auxiliá-lo, também, na definição das funções de custo mais adiante.

TABELA 4.4 - Avaliação do planejador quanto as possíveis conseqüências dos erros de superestimar e subestimar

<i>Incerteza</i>	Vai precisar calcário ou não?
<i>Superestimar</i>	Colocar calcário a mais e ter gastos desnecessários com calcário?
<i>Subestimar</i>	Deixar de colocar o calcário diminuindo a produtividade?
Quatro Possibilidades de Decisão	
Decidir corretamente	Colocar calcário e o solo estar necessitado
Decidir corretamente	Deixar de colocar calcário e o solo não estar necessitado
Decidir erroneamente	Colocar calcário e solo não estar necessitado - <i>Erro de Superstimar (Falso +)</i>
Decidir erroneamente	Não colocar calcário e o solo estar necessitado - <i>Erro de Subestimar (Falso -)</i>

Após um levantamento das possibilidades apresentadas na Tabela 4.4 é possível associá-las aos riscos α e β , como mostra a Figura 4.16. Esse Quadro é uma adaptação da Figura 3.5, apresentado nos procedimentos metodológicos. Deve-se considerar aqui, que para estabelecer os riscos de falso positivo (risco α) e falso negativo (risco β), a situação é considerada positiva para o solo que necessita de calcário.

	Estima-se que NC	Estima-se que Não NC		Estima-se que NC	Estima-se que Não NC
Solo NC	CLASSIFICAÇÃO CORRETA	Falso (-) Erro de Subestimar	Solo NC	CLASSIFICAÇÃO CORRETA	RISCO β
Solo Não NC	Falso (+) Erro de Superestimar	CLASSIFICAÇÃO CORRETA	Solo Não NC	RISCO α	CLASSIFICAÇÃO CORRETA

FIGURA 4.16 - Riscos α e β indicando as classificações em função das estimativas para a reposição ou não de calcário no solo.

Os riscos α e β foram definidos no capítulo 3, mas aqui terão as formulações retomadas, na Figura 4.17, a seguir, para facilitar a compreensão do leitor.

Risco $\alpha(u)$ = é o risco de classificar errado uma localização u como NC, para todas as localizações u onde:

$$Z^*_L > Z_c$$

FALSO POSITIVO (estima-se que necessita, **MAS** existe probabilidade de **NÃO** necessitar)

Risco $\beta(u)$ = é o risco de classificar errado uma localização u como não NC, para todas as localizações u onde:

$$Z^*_L = Z_c$$

FALSO NEGATIVO (estima-se que não NC, **MAS** existe probabilidade de NC)

FIGURA 4.17 - Definição dos riscos α e β .

$$\mathbf{a}(\mathbf{u}) = \text{Pr ob}\{Z(\mathbf{u}) \leq z_c \mid z_L^*(\mathbf{u}) > z_c, (n)\} \quad \mathbf{b}(\mathbf{u}) = \text{Pr ob}\{Z(\mathbf{u}) > z_c \mid z_L^*(\mathbf{u}) \leq z_c, (n)\}$$

$$= F(\mathbf{u}; z_c \mid (n)) \quad = 1 - F(\mathbf{u}; z_c \mid (n))$$

Onde: z_L^* indica uma estimativa ótima escolhida para calcular $\text{NC}(\mathbf{u})$ e z_c é o limiar definido pelo usuário, no caso, $z_c=0$, ou seja, $\text{NC}(\mathbf{u})=0\text{t/ha}$.

A equação que define o risco α deixa claro que, corresponde à probabilidade acumulada em z_c e, só ocorre nas localizações \mathbf{u} onde o valor estimado pelo estimador ótimo adotado, for maior que o limiar de corte z_c . Este cálculo só é efetuado nas localizações \mathbf{u} , onde o valor estimado for maior que o limiar z_c .

O programa POSTSIM da GSLIB possibilita o cálculo destas probabilidades. Já o risco β corresponde à probabilidade em \mathbf{u} ser maior que o limiar de corte z_c , dado que esta probabilidade é calculada apenas para as localizações onde o valor ótimo estimado de NC for menor ou igual ao limiar de corte z_c .

As Figuras 4.18 e 4.19 apresentam os mapas de riscos α e β , respectivamente, para $z_c=0$ e $z_L^* = q_{70\%}$. Estes mapas estão apresentados como mapas coropléticos, com uma legenda de cores fatiada com probabilidades de 20% em 20%.

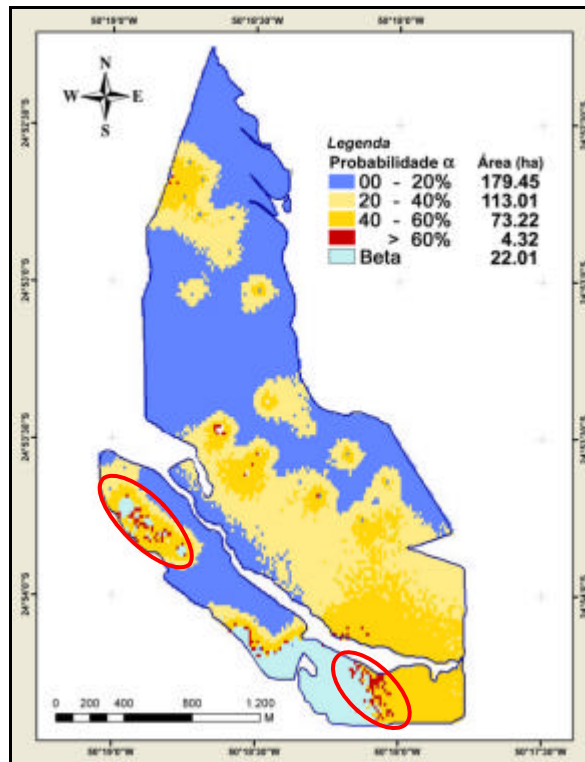


FIGURA 4.18 - Mapa apresentando áreas de risco α , para $q_{70\%}$.

Valores altos de risco α indicam alta probabilidade de colocar calcário onde não há necessidade. No mapa da Figura 4.18 são as áreas em vermelho que apresentam risco α maiores que 60%. No entanto, como indicado pelas elipses na Figura, são poucas as localizações com estes valores e representam cerca de 4.32 ha. A maior parte da área, 179.45 ha, dos 392 ha totais, apresentam risco α entre 0% e 20%. A faixa de 20% a 40% corresponde a aproximadamente 113.01 ha e a faixa de 40% a 60% corresponde à aproximadamente 73.22 ha. Estes valores de probabilidade traduzem a incerteza das estimativas e cabe ao planejador definir o quanto de risco ele está disposto a aceitar.

Deve-se observar o cuidado em apresentar as áreas de risco em cores que indicam um crescente de probabilidades, sendo o vermelho representativo do nível de risco considerado extremo. Essas cores estão associadas também na tabela, para facilitar a identificação por parte do planejador.

No caso em questão, o mapa associado à tabela, apresenta para o planejador uma alternativa interessante do ponto de vista de análise de risco, já que quanto maior for o

Risco α , maior será a probabilidade de planejador estar aplicando recursos de forma equivocada. Verifica-se ainda, que para o caso em questão, o percentual de Risco α alto não atinge uma área muito extensa, o que coloca o planejador numa situação confortável para a tomada de decisão.

Uma abordagem apresentada em Gestão de Riscos, Norma AS/NZS (2004), foi adaptada para este estudo e é apresentada no Tabela 4.4. Uma visão interessante para acompanhar este tipo de mapa é agregar tabelas que explicitam o risco e algumas possibilidades de ação, de modo a facilitar o trabalho do tomador de decisão, como na Tabela 4.5.

TABELA 4.4 - Descrição dos riscos e conseqüências.

Probabilidade de Ocorrência do Evento	Conseqüências				
	Insignificante	Menor	Moderada	Maior	Catastrófica
Quase Certa	Moderado	Alto	Extremo	Extremo	Extremo
Provável	Moderado	Alto	Extremo	Extremo	Extremo
Possível	Baixo	Moderado	Extremo	Extremo	Extremo
Improvável	Baixo	Baixo	Alto	Alto	Extremo

Legenda:

Quase certa - Espera-se que ocorra na maioria das vezes
Provável - Provavelmente ocorrerá na maioria das vezes
Possível - Deverá ocorrer alguma vez
Improvável - Poderá ocorrer alguma vez

Risco Extremo (1) - Necessária Ação Imediata
Risco Alto (2) - Necessária a Atenção da Alta Direção
Risco Moderado (3) - A responsabilidade da Direção deve ser Especificada
Risco Baixo (4) - Gerenciamento por Procedimentos de Rotina

Conseqüência Insignificante - Não afeta o desempenho, **Pequena perda financeira**
Conseqüência Menor - Desempenho afetado, problema deve ser mitigado, **Média perda financeira**
Conseqüência Moderada - Tratamento mais específico necessário, problema deve ser mitigado, **Média perda financeira**
Conseqüência Maior - Graves problemas no desempenho, perda da capacidade de produção, **Alta perda financeira**

FONTE: Adaptada da Norma AS/NZS 4360:2004.

TABELA 4.5 - Resumo do risco α e das possibilidades de decisão.

EVENTO: REPOSIÇÃO DE CALCÁRIO						
Risco	O que pode acontecer	Conseqüências do Evento		Decisão	Nível de Risco	Área em ha
		Probabilidade	Conseqüências			
Alfa Solo Classificado Necessitando de Calcário, mas Solo Não Necessita	Gasto Desnecessário com a Compra de Calcário; Excesso de Calcário no Solo.	0% - 20%	Insignificante	Ordenar as áreas que apresentam a baixo para receber calcário primeiro, caso haja restrição financeira; ou Avaliar a necessidade de reamostragem nas áreas de a alto.	Baixo	179.45
		20% - 40%	Menor		Médio	113.01
		40% - 60%	Moderada		Alto	73.22
		> 60%	Maior		Muito Alto	4.32

A Tabela 4.5 apresenta de forma simples o comportamento do risco em relação às áreas quantificadas. Em conjunto com a análise do mapa, a tabela direciona o tomador de decisão em função da informação do risco. Essa informação pode ser utilizada considerando níveis máximos de incerteza toleráveis, segundo a visão do tomador de decisão. Neste contexto, o mapa de necessidade de calcário pode, também, ser construído, restringindo as áreas que necessitam de calcário, aos valores considerados pelo usuário como limítrofes de risco (Figura 4.19), através dos riscos α e β .

A primeira avaliação do planejador, nesta abordagem, deve direcioná-lo para otimizar os custos de produção e, portanto, as áreas que indicam *NC baixa* e riscos α e β baixos, seriam as primeiras a serem analisadas. A Figura 4.19 apresenta o resultado do cruzamento das áreas com *NC baixa* (0 a 2 t/ha) e *NC média* (2 a 3 t/ha) com riscos α entre 0% e 40%. Estes valores são aqui considerados como baixo até médio para o risco.

Entretanto, como pode ser constatado na Figura 4.19, este experimento não apresenta áreas com baixa *NC* e poucas são as áreas consideradas com *NC média*. Diante desta situação, o passo seguinte é avaliar as áreas de risco α baixo (0 - 20%) e médio (20 - 40%), porém, com as áreas que representam a maior parte da área de estudo: *NC alta* (3 a 4 t/ha) e *NC muito alta* (acima de 4 t/ha), conforme apresentado na Figura 4.19. A Figura 4.20 mostra espacialmente onde se encontram as áreas, apontadas na Tabela 4.5, e que vão exigir um gasto maior de insumo.

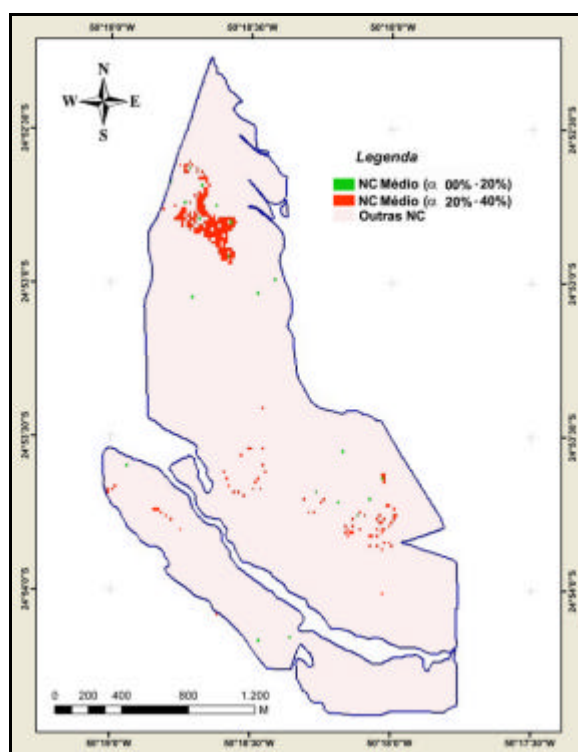


FIGURA 4.19 - Mapa indicando áreas de NC média, condicionadas ao risco α , entre 0% e 40%.

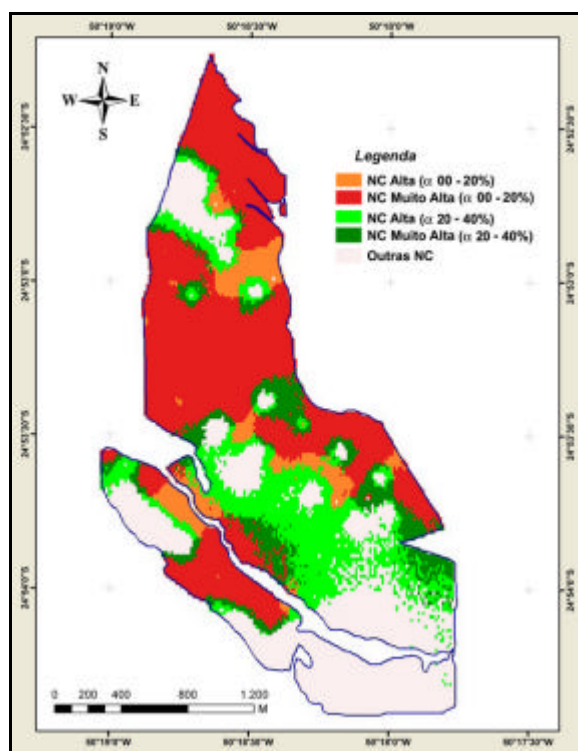


FIGURA 4.20 - Mapa indicando áreas de NC alta e muito alta: condicionadas ao risco α , somadas entre 0% e 40%.

Observa-se que quando a probabilidade do falso positivo aumentou, $\alpha = 40\%$, as áreas que indicam NC alta e muito alta, diminuíram, mostrando que a maior parte da área está com risco α considerado baixo. Embora a NC indicada exija maiores gastos com a colocação de insumo, a probabilidade de estas áreas estarem classificadas erradas é baixa, o que é um indicador positivo para o planejador em termos de gerenciamento da área. Mostra, também, a importância da informação do risco na tomada de decisão.

Este tipo de análise pode orientar o planejador nas ações relativas a novos procedimentos de amostragem em áreas que apresentam NC alta e risco superior a 40%, caso isso seja considerado uma ação apropriada em termos de recursos financeiros e do prazo disponível para realização do plantio.

As áreas com risco α considerado baixo, podem ser indicadas para receber primeiro, por exemplo, investimento para um bom retorno de produção. Lembrando que, no caso da produção, este experimento apenas está considerando o problema de corrigir a acidez do solo. No entanto, a metodologia é perfeitamente viável para quaisquer outras estimativas relacionadas à abordagem da agricultura de precisão, desde que haja um modelo matemático definido e amostras pontuais com atributos numéricos disponíveis.

A mesma análise deve ser efetuada para o risco β , altos valores indicam alta probabilidade de não colocar calcário onde há necessidade, ou seja, o erro do falso negativo. Para a produção, conforme já abordado, este risco teria implicações mais sérias em termos financeiros. No entanto, como pode ser observado no mapa da Figura 4.21 (a), poucas áreas apresentam risco β e, ainda assim, não são valores que podem ser considerados alarmantes, pois, a maior parte está entre 20% e 40% de probabilidade.

Um fator importante a considerar, neste caso, é que o estimador utilizado, $q_{70\%}$, foi justamente adotado para minimizar este tipo de erro, relacionado a subestimar a NC, o que implica em diminuir a ocorrência de áreas com risco β . Esta avaliação é constatada na Figura 4.21 (b), quando ao utilizar o estimador da mediana, o qual não minimiza nenhum dos erros abordados, a área de risco β aumenta. Um indicativo positivo quanto

à importância da escolha correta do estimador a ser adotado diante do problema avaliado.

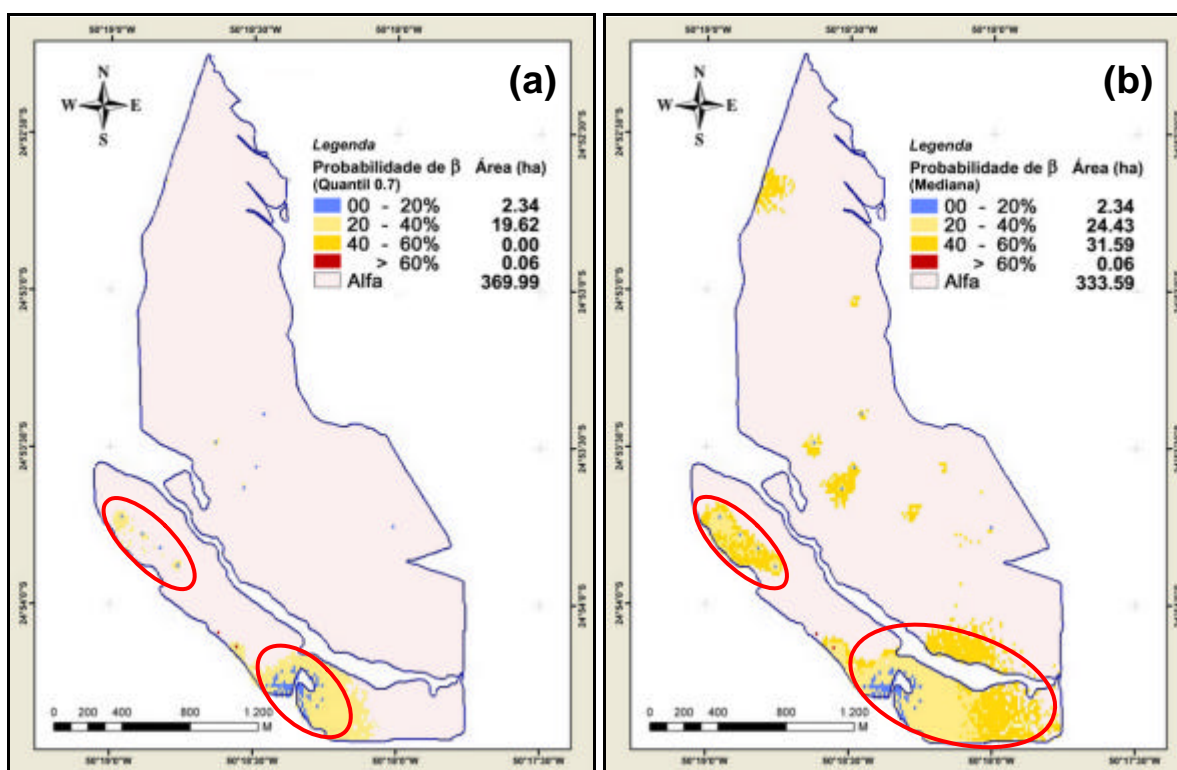


FIGURA 4.21 - Mapa mostrando o risco β com o estimador $q_{70\%}$ (a) e (b) estimador $q_{50\%}$ (mediana), respectivamente.

Optou-se por não gerar mapas do risco β condicionado às estimativas de NC, por se tratar de uma área de pequena abrangência. Entretanto, o planejador deve ter em mente que as áreas de risco β alto, devem ser consideradas como prioritárias para um melhor detalhamento no planejamento amostral, independente da NC estimada ser alta ou baixa

Uma avaliação equivalente à efetuada para o risco α , associando os valores de risco β às áreas afetadas, está apresentada na Tabela 4.6 abaixo.

TABELA 4.6 - Resumo do risco β e das possibilidades de decisão.

EVENTO: NÃO REPOSIÇÃO DE CALCÁRIO						
Risco	O que pode acontecer	Consequências do Evento		Decisão	Nível de Risco	Área em ha
		Probabilidade	Consequências			
Beta Solo Classificado Não Necessitando de Calcário, mas Solo <i>Necessita</i>	Perda de Produtividade; Perda Financeira.	0% - 20%	Menor	Colocar calcário nas áreas que apresentam risco β alto; ou Avaliar a necessidade de amostragem adicional nas áreas de risco β alto.	Baixo	2.34
		20% - 40%	Moderada		Médio	19.62
		40% - 60%	Maior		Alto	-
		> 60%	Maior		Muito Alto	0.06

4.4.2.3 Impacto Econômico das Classificações de Falsos-Positivos e Falsos-Negativos – Terceira Alternativa

O impacto de ter uma área classificada com falso positivo ou falso negativo pode ser avaliado não apenas em termos de quantificação probabilística que define os riscos α e β . Pode, também, ser associado a funções econômicas. Estas funções, definidas pelo planejador, conduzem a uma nova classificação das localizações \mathbf{u} , de modo que a perda esperada, devido aos riscos α e β , possa ser minimizada.

Neste experimento, duas classificações são tratadas: a localização \mathbf{u} pode ser classificada como necessitando de calcário (NC) ou ser classificada como não necessitando de calcário (NNC).

A perda associada à classificação de \mathbf{u} como NC, quando na verdade NNC, reflete o custo, ou a perda, relacionado ao risco α , o qual está associado a superestimar NC. Neste caso, a consequência financeira é ter um gasto desnecessário com calcário. Este custo ou perda pode ser modelado pela função, L_1 , apresentada nas relações definidas em (4.5).

$$L_1 = \begin{cases} 0, & \text{se } z(\mathbf{u}) \geq z_c \\ w_1(z_c - z(\mathbf{u})), & \text{se } z^*(\mathbf{u}) < z_c \end{cases} \quad (4.5)$$

Onde; w_1 é o custo relativo de superestimar a NC do solo e é dado em unidades financeiras/ha; $z(\mathbf{u})$ é a concentração real de NC, $z^*(\mathbf{u})$ é a estimativa de NC, e z_c é o limiar crítico, no caso, NC=0 t/ha.

Se o solo em \mathbf{u} realmente não estiver com acidez controlada e, portanto, está precisando de calcário, $z(\mathbf{u}) = z_c$, a classificação está correta e não há perda devido à classificação. A função L_1 retorna o valor zero. Se, no entanto, a localização \mathbf{u} estiver com acidez controlada, $z^*(\mathbf{u}) < z_c$, a classificação errada acarreta aplicação indevida de calcário, por exemplo, a um custo proporcional à diferença considerada $[z_c - z^*(\mathbf{u})]$, que corresponde

ao que foi indevidamente colocado, ponderada, ainda, pelo custo do calcário e de sua aplicação por hectare.

A função L_1 foi construída seguindo a colocação do parágrafo anterior. Segundo informações da empresa IMPAR (2005) o custo de 1 tonelada de calcário somado à sua aplicação estava em R\$28.00/ha. Portanto, w_1 corresponderia a este valor, se a abordagem adotada neste trabalho não utilizasse uma estrutura de representação de grade. Neste caso, cada modelo de incerteza e cada valor estimado são gerados para cada célula da grade; são, portanto, pontuais, com localização \mathbf{u} . Assim, fez-se necessário ponderar o valor da aplicação do calcário para cada célula da grade, cujo tamanho, em hectare, corresponde a 0.0215ha.

Portanto, se:

1ha de calcário aplicado	R\$28.00
0.0215ha	X

Este valor de X, obtido por uma regra de três simples, resultou em R\$0.603, o que equivale ao valor aplicado de calcário por célula da grade. Assim, $w_1 = R\$0.603$ e, portanto, se a localização \mathbf{u} NÃO estiver realmente necessitando de calcário, $z^*(\mathbf{u}) < z_c$, o custo desta classificação errada em \mathbf{u} é proporcional a segunda parte da função $L_1: \{R\$0.603 * [z_c - z^*(\mathbf{u})]\}$.

No entanto, a perda associada à classificação de \mathbf{u} como NNC, quando na verdade NC, reflete o custo ou a perda que está associada ao erro de subestimar NC. A consequência financeira deste erro pode ser vista sob a óptica de queda de produção e baixo lucro. Sugerem-se duas funções para modelar esta perda, L_2 e $L_{2.1}$, apresentadas na seqüência. A função L_2 , apresentada na relação definida em (4.6), expressa as pesquisas desenvolvidas pela Associação Brasileira dos Produtores de Calcário, ABRACAL, em conjunto com o Ministério da Ciência e Tecnologia. Estes estudos resultaram em um Plano Nacional de Calcário Agrícola, PLANACAL, instituído pela Circular número 245, do Banco Central do Brasil, em 1998. A série de estudos sobre o calcário agrícola

no Brasil, promovidos pelo Centro de Tecnologia Mineral, parte do Ministério da Ciência e Tecnologia do Brasil, (CETEM, 2003), apresenta o PLANACAL.

$$L_2 = \begin{cases} 0, & \text{se } z(\mathbf{u}) \leq z_c \\ w_2(z(\mathbf{u}) - z_c), & \text{se } z^*(\mathbf{u}) > z_c \end{cases} \quad (4.6)$$

Segundo a CETEM (2003) o PLANACAL enfatiza a acidez do solo brasileiro como um fator limitante da produtividade agrícola e propõe estimular a prática da calagem em todo território brasileiro, onde seja praticada agricultura. Apresenta como benefícios econômicos um incremento na produtividade de aproximadamente 30% e enfoca que para cada real investido em calcário, o retorno do plano é da ordem de R\$2.40 a R\$3.00. Desse modo, esses valores foram considerados para definir w_2 , com o seguinte raciocínio:

Se:

1 tonelada de calcário	R\$28.00
X	R\$1.00

Portanto, novamente utilizando uma regra de três simples, X equivale a 0.036 toneladas de calcário a um custo de R\$1.00. Assim, a cada 0.036 toneladas de calcário colocada no solo, se ganha R\$3.00 na produção de grãos. No entanto, a definição de w_2 ainda precisa de algumas considerações:

Se ao deixar de colocar 0.036 toneladas de calcário, perde-se R\$3.00 produção. Então, ao deixar de colocar $[z^*(\mathbf{u}) - z_c]$, perde-se X, e ainda, deve-se considerar o ponderador do tamanho da célula da grade, conforme apresentado para função L_1 . Portanto, a segunda parte da função L_2 é definida pela expressão 4.7:

$$L_2 = \left[(z^*(\mathbf{u}) - z_c) * 3.00 / 0.036 \right] * 0.0215 \quad (4.7)$$

Uma alternativa para modelar estes custos de classificações erradas, como proporcionais à NC estimada, $[z^*(\mathbf{u}) - z_c]$, é utilizar o modelo de incerteza, que pode substituir o valor

desconhecido a priori, da NC em u . A partir da fdac é possível determinar a perda esperada que está associada aos dois tipos de classificação, definidas como j_1 e j_2 , apresentadas no capítulo 2, nas equações (2.24) e (2.25).

Assim, cada localização passa a ser re-classificada pelo critério de custo mínimo, como segue:

- u é classificado como NC se, $j_1 < j_2$, isto é, se o custo de classificar errado, como NC for inferior ao custo de classificar errado como NNC, que corresponde a j_2 .
- u é classificado como NNC se, $j_1 \geq j_2$, isto é, se o custo de classificar errado como NNC, for inferior ao custo de classificar errado, como NC que corresponde a j_1 .

Um novo critério de classificação fica definido, portanto, para cada localização u , de modo que u passa a ser declarada como NC ou NNC, quando ocorrer a minimização da perda esperada, resultante das funções de custo adotadas.

A função L_2 foi aplicada para duas situações diferentes: uma para um planejador menos conservador e que acredita que, se não considerar que a cada a R\$1.00, ou 0.036 toneladas de calcário aplicado, ele deixará de ganhar R\$3.00 na produção. Para este caso, pode-se definir w_2 como uma constante que equivale a $(3.00/0.036)*0.0215$, ou seja, 1.79.

A outra situação é definida para um planejador mais conservador, que prefere arriscar menos e, para isso, considera que se deixar de aplicar 0.036 toneladas de calcário, ele deixará de ganhar R\$2.00. Neste caso w_2 equivale $(2.0/0.036)*0.025$, ou seja, 1.19. A minimização da perda esperada gera uma nova classificação em cada localização u e, portanto, um novo mapa, baseado em custos. Os mapas de custo mínimo obtidos comparando L_1 e $L_{2,(R\$3.00)}$ e L_1 e $L_{2,(R\$2.00)}$, podem ser observados na Figura 4.22.

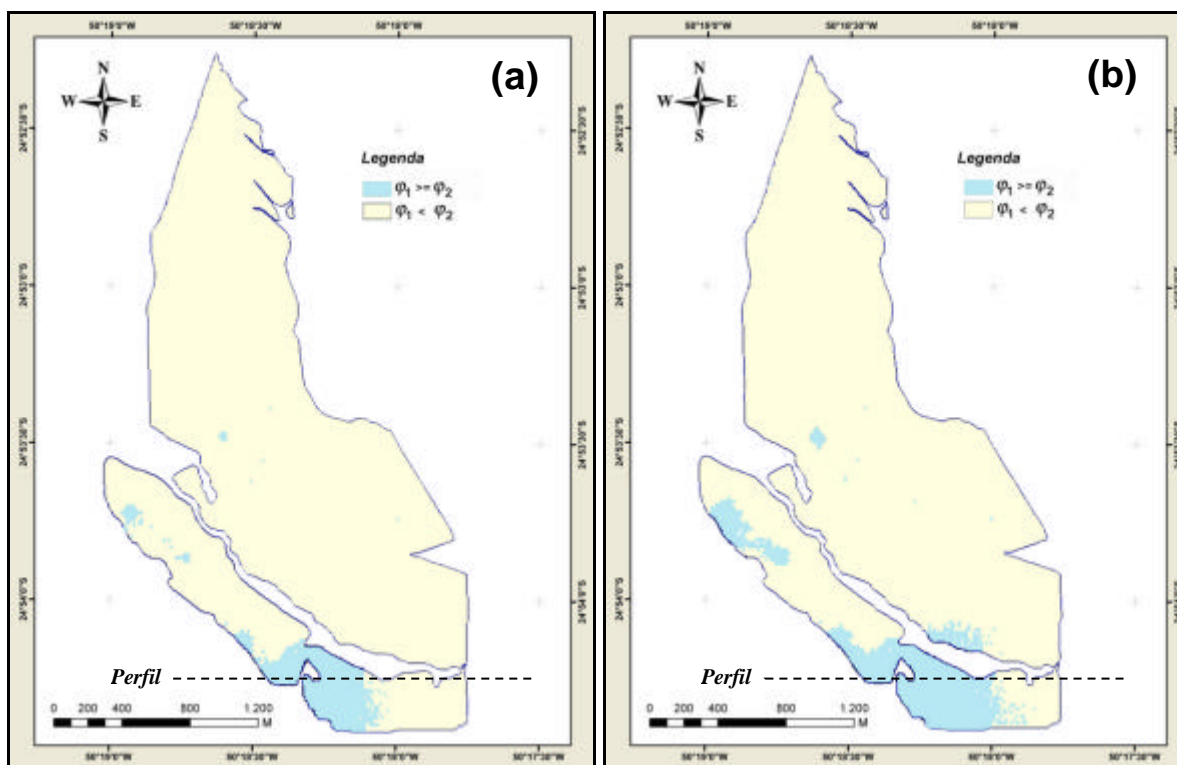


FIGURA 4.22 - Mapas de custo mínimo: (a) funções L_1 e L_2 , (com R\$3.00) e (b) L_1 e L_2 , (com R\$2.00).

Observa-se que na Figura 4.22(a), onde o peso é maior, w_2 aumenta-se a área classificada como NC. Ou seja, quando o planejador decide ser menos conservador (arrojado) para ampliar a lucratividade da lavoura, conseqüentemente ele é conduzido a ampliar a área de reposição de calcário. Esta decisão implica no aumento do “Falso Positivo”, que está relacionado ao risco α e expresso na função L_1 . Na Figura 4.22(a), fica claro que a área em bege, que representa onde compensa colocar calcário, segundo a minimização de custo adotada, é maior que a área em bege da Figura 4.22(b), onde w_2 é menor.

A Figura 4.23 colabora para o entendimento da figura anterior, onde os perfis que demonstram que a ampliação da área possibilita o aumento da lucratividade da lavoura, a partir da aplicação de calcário.

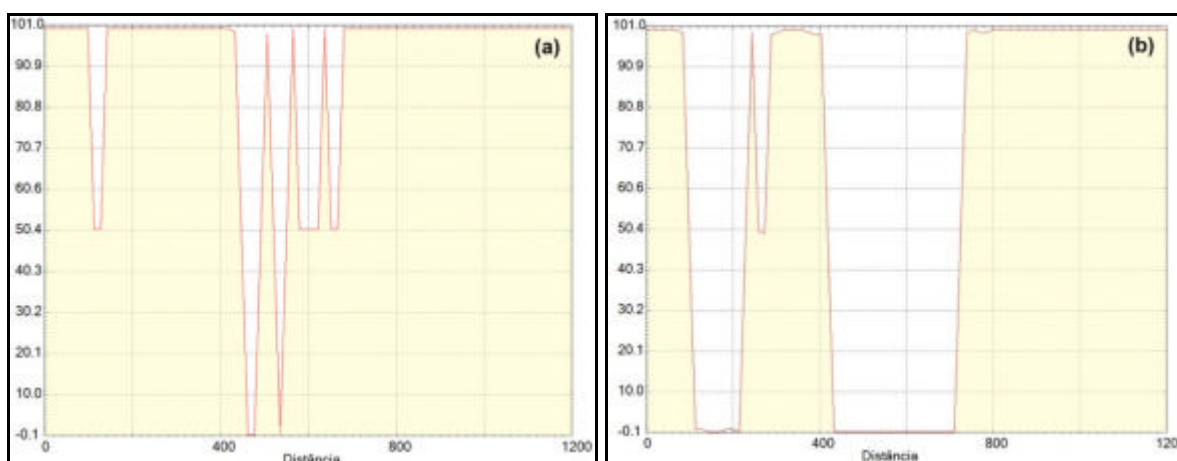


FIGURA 4.23 - Gráficos de custo mínimo: (a) funções L_1 e L_2 , (R\$3.00) e (b) L_1 e L_2 , (R\$2.00).

Outra função, $L_{2,1}$, definida na expressão 4.8, considera o problema de classificação das localizações \mathbf{u} , como NC ou NNC, sob a mesma ótica de produção. Para definir esta função, foi utilizado um estudo realizado por Caires et al. (2005), sobre a eficácia da aplicação de calcário na produção de grãos.

O experimento foi conduzido em região próxima à adotada neste estudo, Ponta Grossa, Paraná, e usou o mesmo método para estimar as necessidades de calcário: o método de saturação de bases. Segundo os autores, a máxima eficiência econômica de produtividade é atingida com 4.5 t/ha de calcário, elevando a saturação de bases a 70%. A curva de produção de trigo, em função da colocação de calcário em toneladas/ha, construída no experimento de Caires et al. (2005), foi adotada como referência neste trabalho. Assumindo-se que a área de estudo encontra-se em condições semelhantes à do artigo citado e teve a coleta dos dados efetuada no mesmo período, no ano de 2005.

$$L_{2,1} = \begin{cases} 0, & \text{se } z(\mathbf{u}) \leq z_c \\ w_2 \times p_cultura(Prod_{MAX} - Prod_{Estimadaem}), & \text{se } z^*(\mathbf{u}) > z_c \end{cases} \quad (4.8)$$

função $z^*(\mathbf{u}) - z_c$

Onde:

- w_2 é o ponderador para cada célula da grade, cujo tamanho, em hectare, corresponde a 0.0215 ha;

- p_{cultura} é o preço da saca de 60 kg da cultura. Este valor deve ser ponderado para hectares. Portanto, no caso do trigo, cotado a R\$28.00 a saca:

1Saca	60kg
Xsacas	1000kg (1tonelada)

ou seja,

$X = 16.66$ sacas. Corresponde ao total de sacas para 1 tonelada.

Deste modo, tem-se:

R\$28,00	1saca
Y	16.66 sacas

A equação 4.9, definida no experimento de Caires et al. (2005), expressa a produtividade de trigo estimada (\hat{y}) em função das quantidades de calcário (QC) colocadas no solo, (x), através de um modelo de regressão. Observa-se o alto coeficiente de ajuste da regressão, 99%. A Figura 4.24 apresenta esta curva de regressão, a qual foi utilizada como base para formular a função de custo $L_{2.1}$.

$$\hat{y} = 1.26 + 1.09x - 0.12x^2, R^2 = 0.99 \quad (4.9)$$

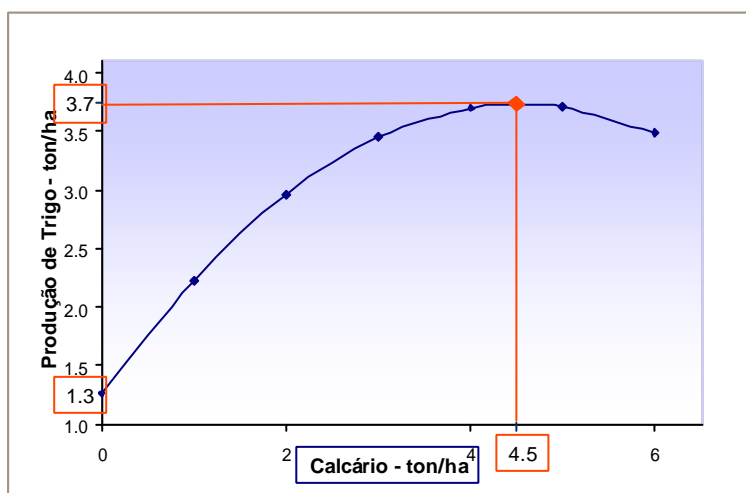


FIGURA 4.24 - Curva de produtividade do trigo versus colocação de calcário no solo.

FONTE: Adaptada de Caires et al. (2005).

Assim, o valor cotado para a cultura, p_{cultura} , deve ser ponderado pelo total de sacas em toneladas para que as unidades de medida fiquem coerentes em toneladas/hectare. Portanto, a função $L_{2.1}$, expressa na relação definida em 4.10, passa a ter a seguinte definição, neste estudo de caso:

$$L_{2.1} = \begin{cases} 0, & \text{se } z(\mathbf{u}) \leq z_c \\ 0.0215 \times 28 (Prod_{MAX} - Prod_{Estimadaem}), & \text{se } z^*(\mathbf{u}) > z_c \end{cases} \quad (4.10)$$

função $z^*(\mathbf{u}) - z_c$

A perda associada à classificação de u como NNC, quando na verdade NC, definida na função $L_{2.1}$, tem a mesma consequência financeira definida para a função L_2 : queda de produção e baixo lucro, porém, com informações obtidas de outra forma.

Quando o valor estimado de necessidade de calcário for zero, para qualquer posição “ u ” da grade, ou seja, $z^*(u)=0$ significa que o solo está com acidez controlada, e, portanto, não há necessidade de colocar calcário. Observando o gráfico da Figura 4.24 verifica-se que a condição de NNC, $z^*(u)=0$, ocorre para a quantidade de calcário correspondente à 4.5 t/ha e corresponde ao solo estar apto para atingir produção máxima, $P=3.375$ t/ha. Acima do valor de 4.5 t/ha o solo já não responde para que a cultura atinja a máxima produção, ocorre o contrário, ou seja, a produtividade começa a baixar.

Estes dados estão coerentes com informações obtidas da fazenda Figueira, onde não mais do que 4 t/ha ou 4.5 t/ha de calcário são colocadas no solo, mesmo que a necessidade estimada apresente valores superiores a este.

Seguindo o raciocínio efetuado acima, quando a NC estimada indicar 0.5 t/ha, admite-se que o solo já está com suprimento de 4 t/ha de calcário, mas ainda falta 0.5 t/ha para máxima eficiência. Nestas condições, a quantidade de calcário, $QC=4$ t/ha e $P=3.7$ t/ha. Ao não atender a $NC=0.5$ t/ha, o agricultor deixa de produzir ($P_{4.5}-P_{4.0}$), que equivale à diferença ($3.735 - 3.7=0.035$ t/ha), ou seja, 35 kg/ha; e assim por diante.

De posse dos valores de produção em t/ha, que não foram atingidos devido a não colocação da QC recomendada, é possível associar valores que definem a perda financeira relativa à esta decisão. A Tabela 4.7 mostra para cada decisão de não colocar

calcário, a perda em produção e a associação financeira com a saca de 60 kg de trigo, segundo a cotação de venda no mercado (cotado em outubro 2007), em torno de R\$28.00.

TABELA 4.7 - Perda de produção e receita de trigo em função da decisão de não colocar calcário no solo.

Necessidade de Calcário (ton/ha)	Calcário no Solo (ton/ha)	Produção de Trigo (ton/ha)	Perda Produção (ton/ha)	Receita com a Produção do Trigo (ton/ha)	Receita Perdida por ha
4.5	0	1,260	(2.475)	R\$ 588	(R\$ 1.155)
4	0.5	1,775	(1.960)	R\$ 828	(R\$ 915)
3.5	1	2,230	(1.505)	R\$ 1,041	(R\$ 702)
3	1.5	2,625	(1.110)	R\$ 1,225	(R\$ 518)
2.5	2	2,960	(0.775)	R\$ 1,381	(R\$ 362)
2	2.5	3,235	(0.500)	R\$ 1,510	(R\$ 233)
1.5	3	3,450	(0.285)	R\$ 1,610	(R\$ 133)
1	3.5	3,605	(0.130)	R\$ 1,682	(R\$ 61)
0.5	4	3,700	(0.035)	R\$ 1,727	(R\$ 16)
0	4.5	3,735	0.000	R\$ 1,743	R\$ 0
(0.5)	5	3,710	(0.025)	R\$ 1,731	(R\$ 12)
(1.0)	5.5	3,625	(0.110)	R\$ 1,692	(R\$ 51)
(1.5)	6	3,480	(0.255)	R\$ 1,624	(R\$ 119)
(2.0)	6.5	3,275	(0.460)	R\$ 1,528	(R\$ 215)
(2.5)	7	3,010	(0.725)	R\$ 1,405	(R\$ 338)
(3.0)	7.5	2,685	(1.050)	R\$ 1,253	(R\$ 490)

Mapas de custo mínimo, também podem ser gerados, analogamente aos dos mapas da Figura 4.22, porém utilizando as funções L_1 e $L_{2,1}$, conforme Figura 4.25.

A análise de sensibilidade é usada para responder quais atributos ou variáveis mais influenciam os resultados de um modelo (PEARLSTINE et al., 2004). No contexto deste trabalho a análise de sensibilidade revela quais critérios são mais prováveis de alterar o resultado para selecionar um cenário alternativo. Análise de sensibilidade pode ser executada fixando todas as variantes do modelo e testando uma só, a qual deve assumir um range de valores.

O preço da saca da cultura é considerado mais sensível, se o preço do calcário for considerado estável. O preço da saca do trigo deve ficar inferior a “K” reais para não compensar colocar o calcário. O que pode não ser válido para a situação do preço do calcário vir a subir ou mesmo ao considerar a metodologia para outro insumo.

A Figura 4.25 apresenta em verde a área, que devido à relação financeira: custo do calcário / preço do trigo, não deve receber calcário, pois o valor obtido com a colheita

não cobriria os custos do plantio, se o calcário fosse aplicado. Cabe ressaltar que por se tratar de uma simulação para análise de similaridade, foram atribuídos valores fictícios à saca de trigo, que no exemplo da Figura 4.25, foi de R\$1.00 (um real).

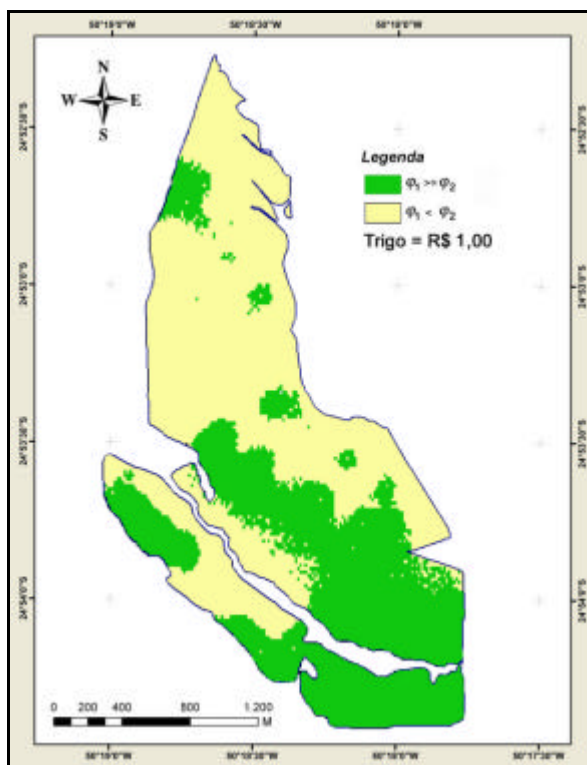


FIGURA 4.25 - Mapa de custo mínimo utilizando as funções L_1 e $L_{2,1}$, considerando custo de aplicação do calcário constante (R\$28.00) e o preço do Trigo a R\$1.00.

Com o intuito de encontrar qual é o preço mínimo que a saca de trigo pode alcançar para que o produtor tenha lucro, realizando a melhor prática agrônômica, foram produzidas várias simulações: o valor do calcário, em t/ha, ficou fixo em R\$28.00 e o preço da saca do trigo foi variando nos seguintes valores: R\$1.00 (Figura 4.25), R\$3.00, R\$5.00, R\$10.00, R\$15.00, R\$18.00 e R\$28.00, este último sendo o valor real da saca de trigo consultado em outubro de 2007.

Como pode ser observada na Figura 4.26, a área inadequada para o plantio vai diminuindo, encontrando o seu ponto ótimo, ou seja, para qual valor da saca de trigo compensa aplicar o calcário recomendado. Isto ocorreu na faixa entre R\$15.00 e R\$18.00. A partir deste ponto, qualquer preço superior a esse, faz com que em toda a área receber calcário na quantidade indicada, seja compensador financeiramente.

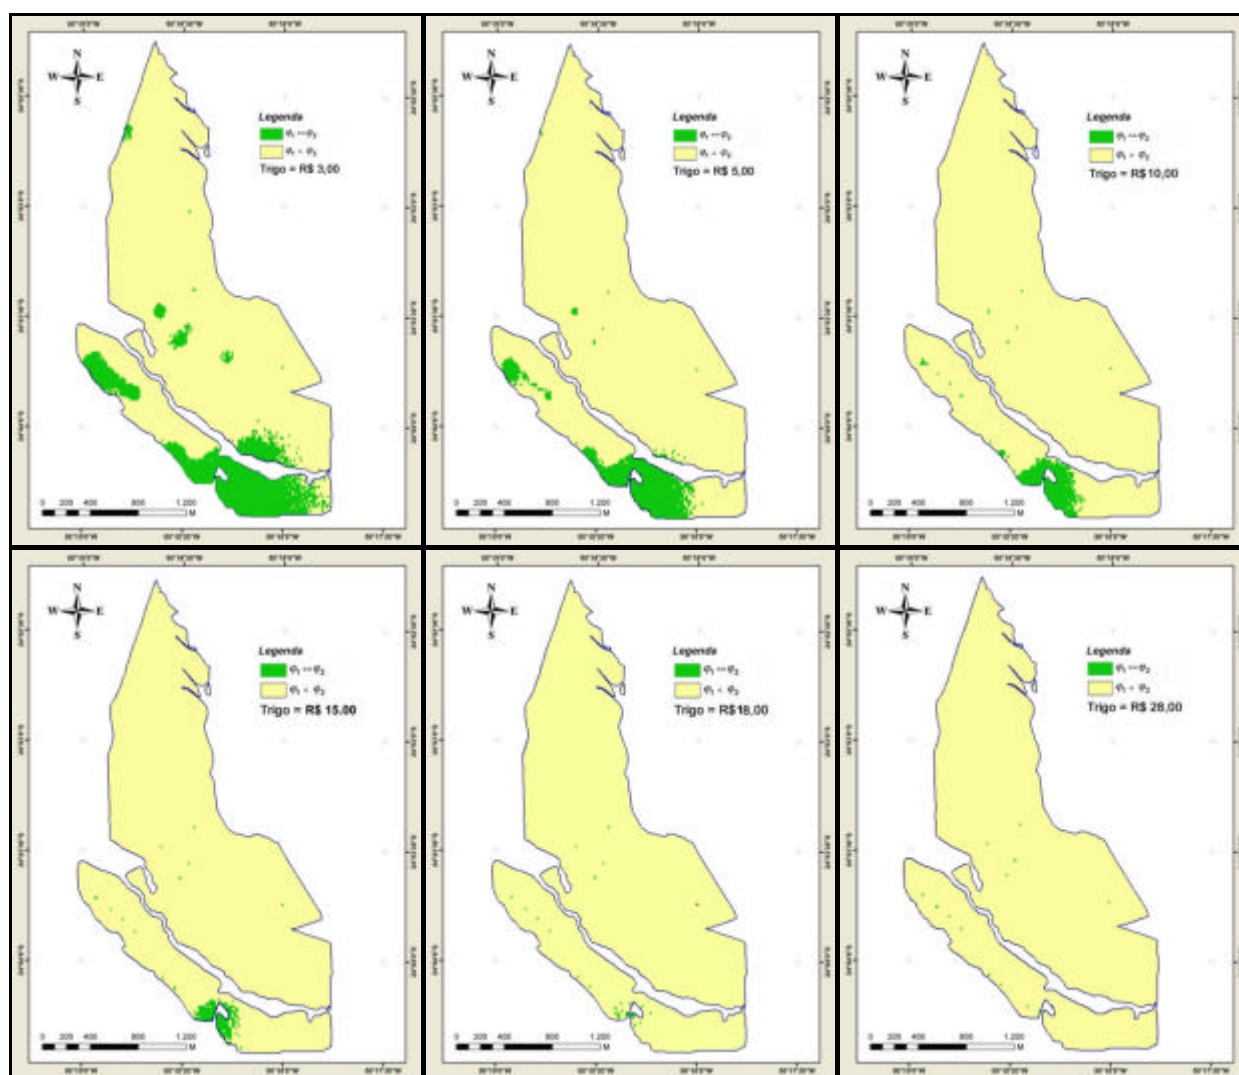


FIGURA 4.26 - Mapas de custo mínimo utilizando as funções L_1 e $L_{2,1}$, considerando custo do calcário constante (R\$28.00t/ha) e o preço do Trigo variando de R\$3.00 à R\$28.00.

TABELA 4.8 - Resumo da perda financeira em função da não colocação de calcário.

EVENTO: NÃO COLOCAR CALCÁRIO						
Risco	O que pode acontecer	Necessidade de Calcário não Atendida (ha)	Perda Financeira (ha)	Consequências do Evento		Nível de Risco
				Probabilidade	Consequências	
Financeiro	Perda de Produção com Consequente Perda Financeira	0.5	R\$ 16.33	Provável	Menor	Baixo
		1	R\$ 60.67	Provável	Menor	Baixo
		1.5	R\$ 133.00	Possível	Menor	Médio
		2	R\$ 233.34	Possível	Moderada	Médio
		2.5	R\$ 361.67	Possível	Moderada	Médio
		3	R\$ 518.01	Improvável	Maior	Médio
		3.5	R\$ 702.35	Improvável	Maior	Alto
		4	R\$ 914.68	Rara	Catastrófica	Alto
4.5	R\$ 1.155.02	Rara	Catastrófica	Alto		

A tabela 4.8 apresenta uma escala qualitativa de risco associado às perdas financeiras, adaptadas do modelo pela Norma AS/NZS (2004).

4.4.2.4 Definição de Áreas para Planejamento – Alternativa Híbrida

A exposição a riscos, objetivamente varia de um planejador para outro, em função das ações e estratégias de cada um e, em relação aos perigos que consideram estar expostos. Além disso, um componente subjetivo, devido à percepção de cada agricultor, que vem da sua experiência, determina diferentes comportamentos e diferentes graus de exposição ao risco.

Parte-se da premissa que a gestão de riscos envolve um conjunto de atividades, onde o primeiro passo é identificar os riscos e sua natureza. Em seguida analisá-los, considerar a possibilidade de sua ocorrência, avaliar as possíveis conseqüências e a necessidade de tomar alguma ação atenuadora.

Dado o modelo de incerteza da NC, alguns caminhos foram apresentados para que considerar a incerteza no processo de tomada de decisão. A abordagem apresentada a seguir procura compor um conjunto de alternativas para o planejador, no sentido de auxiliá-lo na sua percepção sobre o risco e suas conseqüências diante da possibilidade de atenuá-lo para melhor administrá-lo.

Primeiramente propõe-se fixar um nível de probabilidade para que as localizações sejam classificadas segundo esse nível de aceitação, o qual deve ser definido pelo planejador. Esta escolha é subjetiva e pode levar em consideração fatores financeiros ou ambientais, por exemplo. Nessa fase, utiliza-se o modelo de incerteza utiliza-se, construído em cada localização \mathbf{u} da grade regular pelo procedimento de simulação, mas não é necessário, obter estimativas da NC.

Essa abordagem consiste em declarar como NC, todas as localizações onde a probabilidade acumulada de exceder a NC_{ideal} no solo, for maior que um dado limiar de probabilidade, neste caso, adotado como 75%. As probabilidades de exceder um limiar considerado crítico, dado o modelo da fdac em cada localização \mathbf{u}_j , $j=1,\dots,N$, correspondem a $\{ 1 - [F(\mathbf{u}_j; z_c^{prob} | (n))]^* \}$.

A utilização da biblioteca de geoestatística GSLIB (DEUTSCH e JOURNAL, 1998), através do aplicativo POSTSIM, para processamentos pós-simulação, gerou estas probabilidades e para melhor compreensão do leitor a Figura 4.27 ilustra uma situação hipotética para mostrar como são obtidas. Para melhor compreensão do gráfico a NC_{ideal} não foi considerada igual a zero. Como, neste experimento o limiar de probabilidade foi fixado em 75%, todas as localizações onde a probabilidade de exceder $z_e = NC_{ideal}$, for maior que 75% estas localizações serão classificadas como NC.

Na Figura 4.27 (b), u_2 é classificada como NC, pois, $[1-0.5=95\%]$, ou seja, é superior ao limiar crítico de probabilidade de 75%. No entanto, a localização u_1 não recebe a mesma classificação, pois, $[1-0.95=5\%]$ e, portanto não é superior ao limiar de 75%. O que ocorre na prática é que o insumo não é aplicado em quantidades variáveis em cada localização u_j , classificada como NC. Deve-se formar um bloco de localizações vizinhas, contíguas, para receber a mesma quantidade de calcário. As áreas restantes, ficam em estado de espera, aguardando um refinamento da análise, conforme a seguir.

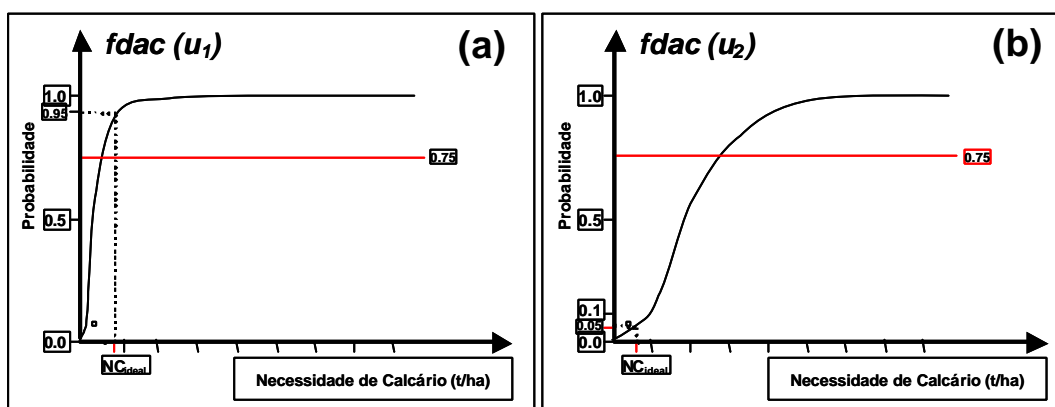


FIGURA 4.27 - Ilustração do cálculo das probabilidades acumuladas, segundo em um limiar de NC_{ideal} : (a) $Prob\{NC(u_1) = NC_{ideal}\} = 95\%$ e (b) $\{Prob\{NC(u_2) = NC_{ideal}\} = 5\%$

O arquivo de probabilidades acumuladas resultante foi transformado em um mapa coroplético, estabelecendo faixas com probabilidade de exceder 75%. Estas faixas foram associadas a cores e apresentadas na Figura 4.28.

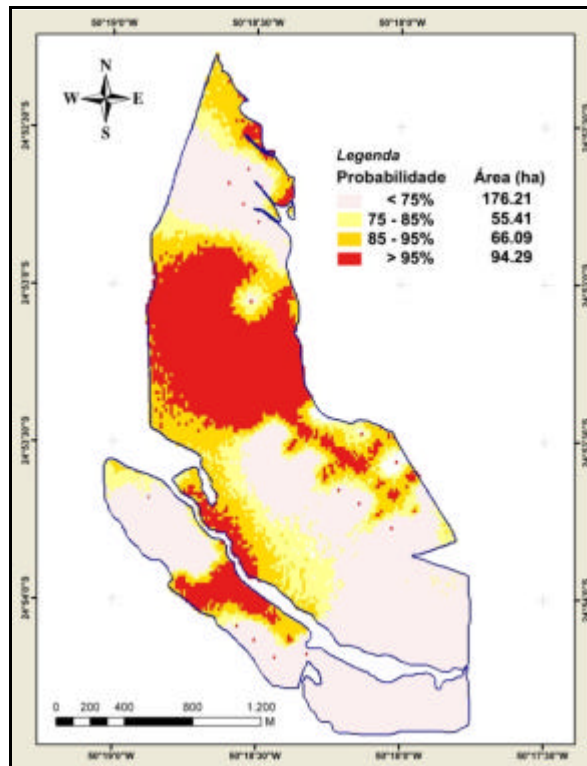


FIGURA 4.28 - Mapa de Probabilidade da NC_{ideal} exceder 75%.

Na Figura 4.27, as áreas em vermelho, indicam alta probabilidade de exceder o limiar de 75% (maiores que 95%) de NC, correspondem a 94.29 ha, de um total de 392 ha (área total dos talhões). Em seqüência decrescente, as probabilidades de exceder o limiar de 75% para NC_{ideal} , aparecem as áreas em laranja, com probabilidades entre 85% e 95%, correspondentes a aproximadamente 66 ha; e por fim as áreas amarelas, com probabilidades entre 75% e 85%, aproximadamente 55.41 ha. Esta qualificação possibilita a restrição de áreas específicas para planejamento, sabendo-se que são áreas classificadas como NC, são áreas onde, de acordo com os limiares adotados, necessitam de correção de calcário. No entanto, não se sabe ainda, nesta etapa, quais quantidades de calcário o solo está exigindo em cada localização. Como a aplicação de insumos deve ser efetuada em blocos, por faixas de quantidades de calcário e não pontualmente, as estimativas de NC devem vir em seguida. Todos os blocos marcados como NC podem, portanto, ter indicação para manejo imediato, segundo o limiar de probabilidade e de NC_{ideal} estabelecidos como aceitável. Sugere-se, assim, que todas estas áreas que fazem parte de um bloco macro, sejam denominadas A_1 . O bloco A_1 passa a designar área disponível para planejamento imediato.

Por outro lado, o restante da área da Figura 4.28, em cor lilás, representa as localizações onde a probabilidade de exceder a NC_{ideal} no solo mostra-se inferior a 75%. Estas áreas podem estar requerendo correção de calcário, mas a probabilidade acumulada neste evento está se mostrando menor ou igual ao limiar fixado de 75%. Assim, todas as localizações nesta condição são classificadas como integrantes de A_2 . Desta forma, A_2 configura-se um bloco na situação de espera para planejamento. Talvez mais informações sejam necessárias para planejar a colocação do insumo neste bloco.

Vários ensaios podem ser realizados pelo planejador, alterando o limiar de probabilidade e, caso o problema permita, o limiar de calcário ou qualquer outro insumo em questão, também pode ser alterado. Desta forma, outros cenários possíveis para iniciar o planejamento podem ser constituídos.

Deve ficar claro que o planejamento agrícola leva em consideração outras variáveis, como por exemplo, a necessidade prática das áreas delimitadas pelo limiar de probabilidade serem contíguas e com um tamanho aceitável para viabilizar o seu manejo. Deste modo, o planejador pode, também, avaliar se as áreas em A_2 têm condições de sofrer uma pronta intervenção no sentido de transformá-las em áreas que possam ser incorporadas ao planejamento imediato. Neste contexto, podem-se apresentar opções que viabilizem o planejamento.

Opção 1

Ampliar a área para planejamento imediato, diminuindo-se o limiar de probabilidade ou aceitação (aumenta-se a incerteza): delimitando-se, assim, regiões onde a probabilidade de exceder NC_{ideal} é maior que 60% (Figura 4.29).

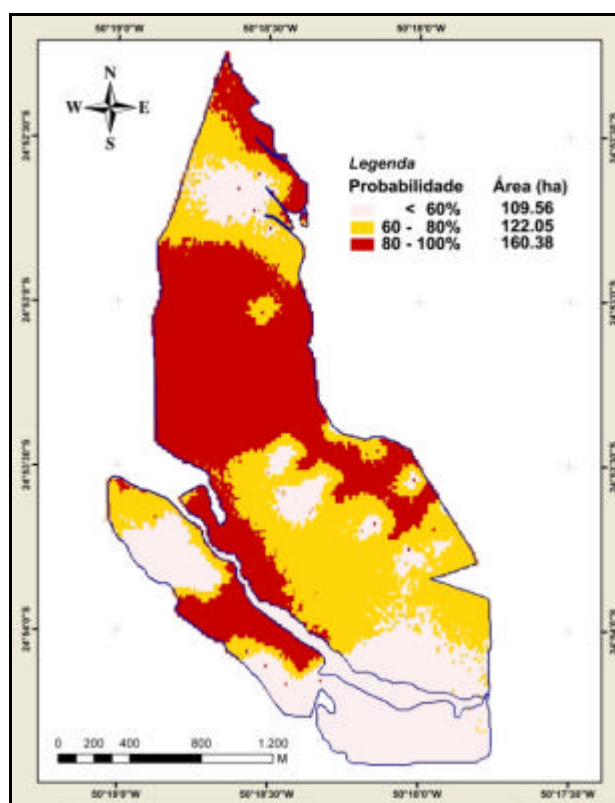


FIGURA 4.29 - Mapa apresentando regiões onde a probabilidade de exceder $NC = 0$ t/ha é maior que 60%.

Diminuir o limiar de aceitação implica em aceitar incerteza maior e com isso, mais áreas são classificadas como aptas ao planejamento imediato. O planejador, neste caso, está sendo menos rigoroso com a incerteza. Desse modo, o tomador de decisão menos conservador, talvez opte por arriscar plantar em mais áreas. Já o tomador de decisão mais conservador, talvez com menos recursos disponíveis, pode optar por plantar em áreas menores, mas com um retorno mais seguro.

Opção 2

Ao fixar o limiar de aceitação em 75%, duas áreas ficam definidas e podem ser avaliadas quanto à incidência dos riscos α e β , efetivando a abordagem denominada híbrida:

- A_1 , área acima do limiar de probabilidade definido e que ao ser cruzada com os níveis de risco α , vai definir novos limites de planejamento imediato para a aplicação de calcário.
- A_2 , área que indica necessitar de mais informações para planejar a aplicação do calcário; pode, por exemplo, ser destinada à reamostragem ou adensamento de amostras, para ampliar a área de correção e plantio. No caso em questão o planejador pode decidir pela reamostragem, ao avaliar a incidência de altos valores de risco α em A_2 ; ou pode decidir agregar A_2 à área A_1 , caso A_2 apresente riscos α baixos.

Com o exposto acima, o planejador, pode analisar os resultados obtidos em função dos conceitos de risco α , e, também, funções de custo. A Figura 4.30 mostra o resultado da álgebra de mapas nas áreas A_1 e A_2 , com o mapa de riscos α .

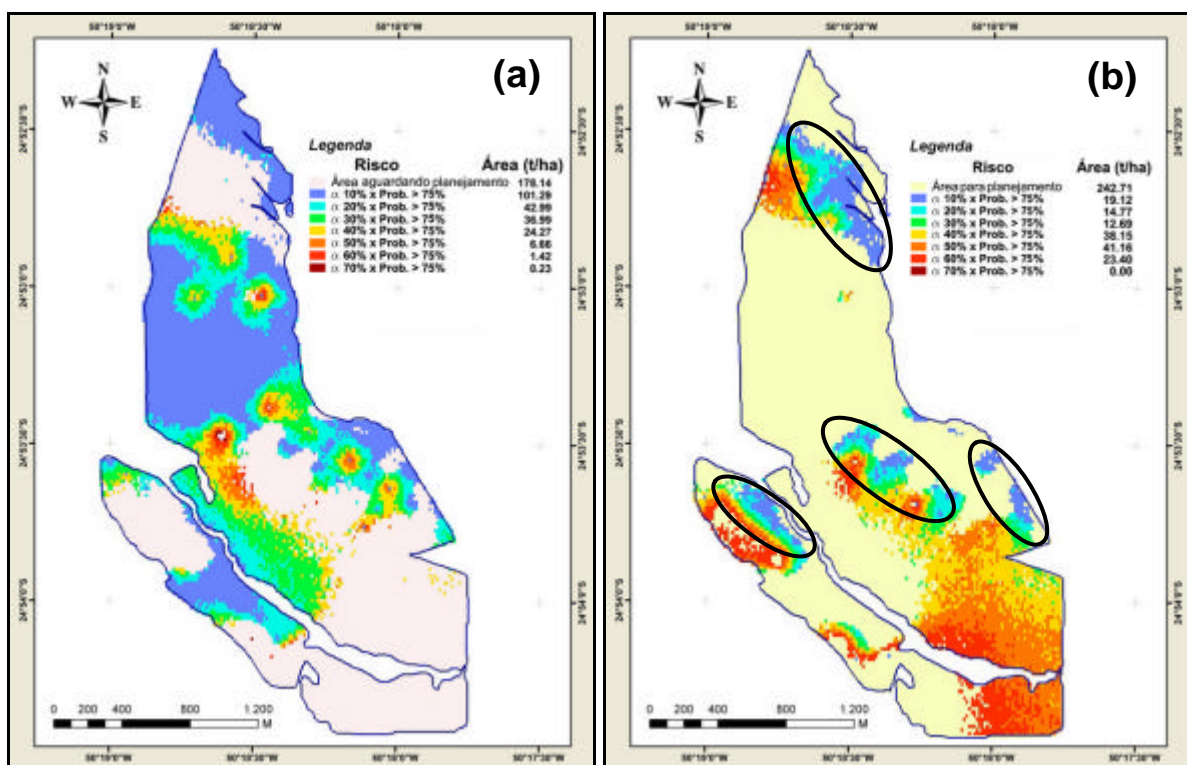


FIGURA 4.30 - Mapa resultante do cruzamento (a) de A_1 com riscos α e (b) de A_2 com riscos α .

Mesmo na área A_1 , Figura 4.30a, teoricamente já considerada apta ao planejamento, algumas regiões com risco α de 40% a 70% totalizando 32.59 ha, podem ser reavaliadas pelo planejador, indicadas para a reamostragem, ou mesmo, ordenadas para reposição de calcário em função da disponibilidade de recursos, por exemplo. Primeiro, receberiam calcário as áreas com mais certeza de estarem necessitando do insumo.

Na Figura 4.30b, observa-se à ocorrência de áreas (contornadas por elipses) com risco α de 10%, 20% e 30%, totalizando 46.58 ha, que dependendo da análise do planejador, estes podem ser considerados aceitáveis. Deste modo, tais áreas em A_2 poderiam ser incorporadas em A_1 .

A mesma avaliação pode ser efetuada com risco β , Figura 4.31, o qual ocorreu praticamente em toda área A_2 . Esta área seria candidata à reamostragem, antes de qualquer outra área que apresente risco α alto. Pois, o risco β é considerado mais prejudicial, segundo a premissa deste trabalho, para a queda de produção.

Assim, se a área com risco β , 21.81 ha, apresentada na Figura 4.31, cuja NC estimada está entre 1.0 – 2.0 ton/ha (Figura 4.14), for selecionada para o processo de reamostragem, o planejador terá que considerar um custo de produção extra. Para realizar este procedimento, considerou-se um custo fixo de R\$18.00 por ha (IMPAR, 2005), obtendo-se um custo total para a área de R\$392.58.

Analisando este valor juntamente com a Tabela 4.7, que apresenta os valores de perda de produção por ha, verifica-se que a cada 0.5 tonelada de calcário que o produtor deixa de colocar no solo, a perda de produção e, conseqüentemente, a perda de receita é superior ao valor apresentado para a realização da reamostragem, o que indica que reamostrar é compensador.

A avaliação de riscos na agricultura é uma ferramenta que pode ser usada para estimar e hierarquizar a importância de determinada ação, calculando quantitativamente os impactos que vão ser gerados para os agricultores e também ao meio ambiente. Embora este último não seja escopo da presente avaliação.

É importante salientar que os diferentes tipos de risco que podem estar envolvidos na agricultura, como os recursos humanos, os riscos de produção, preço, insumos, variações climáticas, podem afetar cada agricultor de forma diferenciada. Podem-se encontrar agricultores preocupados com as oscilações de preço de mercado e o retorno da produção; outros, mais preocupados com a falta de chuvas e assim por diante. Esse experimento adotou um risco específico que está relacionado à correção da acidez do solo, através da reposição de calcário e que tem relação direta com a produção de grãos.

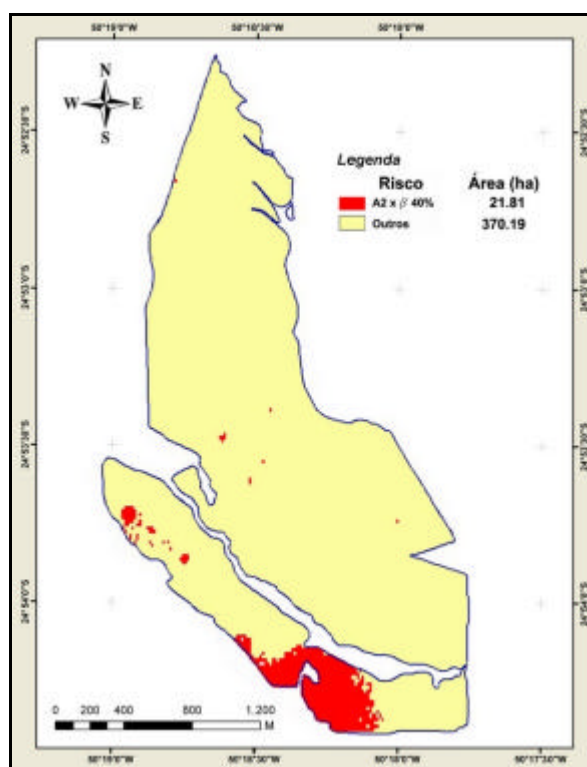


FIGURA 4.31 - Mapa mostrando regiões de risco $\beta=40\%$ na área definida como A_2 .

Os resultados apresentados buscam fornecer e definir algumas regras de decisão associadas a custos ou perdas financeiras, as quais estão vinculadas aos modelos de risco definidos pelos procedimentos inferenciais adotados. Com a quantificação do risco concluída, seguindo a metodologia proposta, torna-se possível listar algumas opções de tratamento e mitigação para cada risco. Pode-se obter um plano de tratamento dos riscos através da interpretação de uma tabela.

Através da análise da decisão pode-se entender a aplicação de técnicas sistemáticas que fornecem estrutura e indicações para tomar uma decisão. DeAngelis et al. (2004), sugerem 3 possibilidades para representação dos resultados da análise de decisão para os tomadores de decisão:

1. Escolher uma ou mais alternativas ótimas;
2. Ordenar total ou ordenar parcialmente as alternativas, porém sem restringir a decisão final à classificação de ordenamento;
3. Fornecer uma análise de aceitabilidade das alternativas, como a descrição de quais tipos de preferências levariam a melhor classificação, ou uma classificação específica para cada alternativa.

As duas últimas alternativas fornecem mais flexibilidade e os resultados dessas análises podem sugerir novas possibilidades.

Uma tabela para auxiliar decisões pode ter alguns componentes básicos. Um desses componentes é uma análise de quais cenários estão sendo propostos e seus impactos financeiros, por exemplo. Essas análises são auxiliadas pela simulação de cada cenário, variação da cultura avaliada, preço da saca no mercado, preço do insumo, no caso o calcário, por exemplo. Alterações destes parâmetros se refletem no ganho do produtor. Devem-se levar em conta que nessa análise não estão sendo considerados efeitos ambientais dos eventos envolvidos, apenas os possíveis efeitos financeiros.

Os tomadores de decisão não querem um método computacional para tomar decisão para eles. Eles são os responsáveis pelas conseqüências da decisão e devem ter a liberdade de desviar ou não da solução modelada. Portanto, o ideal seria apresentar um ordenamento de soluções. A tabela 4.9 apresenta uma opção para este ordenamento.

TABELA 4.9 - Sugestão de ordenamento dos riscos abordados e suas conseqüências.

OPÇÕES PARA PLANEJAMENTO	O que pode acontecer	Conseqüências do Evento		Nível de Risco	Prioridade do Risco
		Conseqüências	Probabilidade		
OPÇÃO 1	Ampliar área de planejamento, diminuindo o limiar de aceitação	Moderada correndo o risco de diminuir produção	Possível	Moderado	1
OPÇÃO 2	Confrontar o limiar escolhido com os risco α e β , definindo áreas para planejamento imediato	Menor possibilidade de minimizar perda de produção	Possível	Moderado	1

A escolha da opção que vai definir o manejo mais adequado para área é de responsabilidade do planejador. No entanto, neste caso, sabendo-se que se trata de uma área controlada por sistema de agricultura de precisão, já com certa estabilidade, pode-se sugerir a opção 2. Esta opção apenas requer do planejador mais capacidade de análise através dos mapas e informações que gerados, sem acréscimo de custos financeiros relativos ao processo de reamostragem. Em resumo, a opção 2 mostra-se como um refinamento da opção 1.

Este capítulo teve por objetivo apresentar os resultados de um estudo de caso, com várias alternativas constituídas por indicadores que compõem vetores de decisão. Estes indicadores orientam a ação a ser tomada, apresentam o cenário de atuação em função desta ação e o risco associado a cada ação. Busca-se, assim, viabilizar a elaboração de um planejamento que reflita a minimização de custos e a otimização da produção.

No Capítulo seguinte apresentam-se as conclusões deste trabalho e sugestões para futuros desenvolvimentos.

CAPÍTULO 5

CONSIDERAÇÕES FINAIS E CONCLUSÕES

Esta Tese apresenta, a integração de procedimentos geoestatísticos e funções de custo para a definição de parâmetros de planejamento em sistemas de produção agrícola. Esta integração permite a construção de cenários de produção especializados, os quais consideram a quantificação e a representação da variabilidade espacial do risco e suas tendências, visando otimizar o processo de tomada de decisão.

Dado o modelo de incerteza, constituído pela função de distribuição de probabilidade, determinada pelo procedimento geoestatístico de simulação seqüencial por indicação, quatro alternativas metodológicas foram propostas e analisadas, e os resultados indicam que o objetivo do trabalho foi alcançado.

Estas alternativas conduziram a um conjunto de alternativas para tomar decisões, composto pelos seguintes parâmetros: ações possíveis de intervenção, impactos ou cenários futuros, viabilidade econômica e riscos associados às alternativas propostas. Os resultados e as análises destas alternativas permitiram seguintes conclusões:

A primeira alternativa metodológica apresentada mostra algumas vantagens ao ser comparada com a abordagem atualmente adotada pela empresa IMPAR, para gerar mapas de aplicação de insumos:

- retrata, além das estimativas de calcário, a incerteza propagada no resultado da modelagem espacial da necessidade de calcário;
- analisa as vantagens e desvantagens dos erros de superestimar e subestimar o valor do atributo em estudo. Com isso, mostra a relevância de se escolher o estimador ótimo adequado, ao possibilitar a minimização desses erros, em função do problema que estiver sendo avaliado.

Assim, conclui-se que ao utilizar esta proposta o planejador agrega essas informações de incerteza, através de uma solução, que embora tenha certa complexidade em seus procedimentos, objetiva a capacidade de fazer escolhas no processo decisório. As funções de análise espacial, utilizadas nesta proposta, encontram-se disponíveis na maioria dos SIG abertos e livres como o SPRING e nos comerciais.

A segunda alternativa, acrescenta à primeira, informações além das estimativas da NC nas localizações não amostradas. Agrega os conceitos de erros de falso-positivo ou falso negativo, os quais derivam do processo de inferência utilizado para gerar valores do atributo nos locais não amostrados. A partir destes conceitos, conclui-se que:

- é possível quantificar os riscos de tomar uma decisão equivocada, dimensionando o risco de decidir sobre um resultado de falso positivo, relacionado ao erro de superestimar o valor de NC. Analogamente, o risco de decidir sobre um falso negativo, relacionado a subestimar o valor de NC;
- é possível apresentar a variabilidade espacial do risco e condicionar o risco espacializado às estimativas resultantes de modelagem espacial para dados com atributos numéricos. Cenários diferentes podem ser gerados em função deste condicionamento, ampliando as possibilidades de análise do tomador de decisão.
- é relevante no planejamento, avaliar, qual dos erros gera conseqüências ou impactos mais sérios para o sistema de produção. Do ponto de vista da produção, no experimento realizado, o erro de falso-negativo foi considerado mais importante. Porém, a escolha do estimador ótimo, apresentado na primeira proposta, foi definida justamente para minimizar este erro, devido às suas conseqüências. O experimento comprova que a escolha adequada do estimador minimiza esse erro, quando identificado no planejamento.
- a análise destes riscos é importante para orientar o planejamento de aplicação de insumos agrícolas, em termos de:

- priorizar áreas com riscos baixos e NC baixas, para que sejam planejadas primeiras;
 - avaliar os recursos disponíveis para planejamento, nas áreas onde os riscos apresentarem altos valores de probabilidade, pois, quanto maior for o risco, maior será a probabilidade do planejador estar aplicando recursos de forma equivocada
 - priorizar áreas para realizar reamostragem, o que incluir adensar amostras, caso haja recursos disponíveis, tempo hábil para plantio e colheita, considerando produção e lucro. Uma consideração importante, no caso de reamostragem, diz respeito aos riscos com valores altos, principalmente, nas áreas que exigem altas quantidades de insumo, pois vão exigir mais gastos, e estes podem ser desnecessários.
- uma análise de risco, através da elaboração de tabelas, facilita a administração dos riscos para o planejador. Uma consideração importante é que as tabelas foram adaptadas a partir de um conjunto de normas definidas especificamente para agricultura (QSP - NORMA AS/NZS, 2004), trazendo um ganho para o planejador ao apresentar, de forma resumida, diferentes possibilidades de ação, em função das conseqüências ou impactos de cada risco.

Uma terceira alternativa agrega nova informação ao planejamento, em relação à proposta anterior e efetivamente constitui os cenários definidos no contexto desta Tese. O impacto de ter uma área classificada com falso positivo ou falso negativo pode ser avaliado não apenas em termos de quantificação dos riscos:

- funções econômicas, definidas pelo planejador, conduzem a uma nova classificação das localizações, de modo que a perda esperada, devido aos riscos abordados, pode ser minimizada.
- as funções sugeridas neste trabalho levam em consideração o custo de aplicação do calcário por hectare, a perda da produção ao deixar de colocar o insumo e o

preço da saca da cultura, no caso, o trigo. Alguns cenários foram gerados, variando-se estes parâmetros mostrando que é possível, por exemplo, determinar o preço mínimo que a saca de trigo deve atingir para que o produtor tenha lucro, realizando a melhor prática agrônômica. Neste caso, esta prática refere-se a colocar ou não o calcário no solo.

- Esta nova classificação, ao ser apresentada na forma de mapas, evidencia espacialmente onde o planejador pode arriscar colocando calcário, mesmo que não seja necessário. Ele pode, também, não arriscar, deixando de colocar o calcário mesmo que o solo esteja necessitando, em função de minimizar seus gastos com insumos e melhorar sua produção.

Uma quarta proposta, denominada híbrida, é apresentada e busca conjugar as três anteriores, no intuito de melhorar as condições de análise do planejador. É mais uma opção para o planejador, no sentido de auxiliá-lo na sua percepção sobre o risco, suas conseqüências e uma possibilidade de atenuá-lo.

- Os resultados apresentados nesta quarta proposta definem algumas regras de decisão associadas a custos ou perdas financeiras, as quais estão vinculadas aos modelos de risco definidos pelos procedimentos inferenciais adotados. Com a quantificação do risco torna-se possível apresentar algumas opções de tratamento e mitigação para cada risco, utilizando os conceitos das propostas anteriores e funções de análise espacial em SIG. Pode-se obter um plano de tratamento dos riscos através da interpretação das tabelas e dos mapas, aproximando um SIG de um SADE¹¹, para problemas iguais ou similares ao apresentado.

Foi apresentada neste trabalho uma série de propostas que trazem para o planejador alternativas de ações que tem como objetivo auxiliá-lo no processo de planejamento para plantio em uma determinada área agrícola. A utilização dessas abordagens deve

¹¹ SADE – Sistema de Apoio à Decisão Espacial (MALCZEWSKY, 1999).

levar em consideração a experiência do planejador, seu grau de maturidade tecnológico e a disponibilidade de recursos físicos/financeiros.

Assim, espera-se que um agricultor com um menor nível tecnológico, adote a primeira abordagem, e um planejador que estiver habituado a trabalhar com um ferramental estatístico, pode optar por trabalhar com a segunda e terceira abordagem. Sem dúvida a implementação da quarta abordagem, vai requerer do planejador uma experiência com as abordagens anteriores, pois, esta última agrega a todas as anteriores.

Desta forma, pode-se concluir que a metodologia proposta é adaptável aos diferentes níveis de experiência de cada planejador. Os procedimentos e funções de custo podem ser adaptados conforme a sua necessidade ou grau de desenvolvimento tecnológico, de modo que novas funções e modelos matemáticos diferentes podem ser agregados a essa sistemática de planejamento, no decorrer do tempo, em função de sua curva de aprendizagem e refinamento tecnológico.

A seguir serão apresentadas algumas considerações quanto à metodologia empregada:

- é importante ressaltar que, em geral, os estudos relacionados à simulação geostatística para análise de risco como em Faechner et al. (2002), Guneralp et al. (2007) e Chai et al. (2007), utilizam-se da simulação seqüencial gaussiana, pela sua simplicidade de construção e, com enfoques diferentes ao adotado nesta tese, que efetuou um experimento voltado para agricultura de precisão. Este trabalho, no entanto, adotou a simulação seqüencial por indicação, a qual, requer a modelagem e ajuste de um semi-variograma para cada valor de corte adotado, e permite construir modelos de incerteza em cada localização do espaço, sem, contudo, considerar a suposição prévia de normalidade dos dados.
- foi apresentado e utilizado o método de simulação das principais componentes como uma solução alternativa adequada para efetuar simulação de variáveis correlacionadas.

Assim, a avaliação de riscos provê informações para que a tomada de decisão tenha sustentação racional baseada na melhor informação científica disponível. Desse modo, foram apresentados os aspectos conceituais do risco, no contexto analisado, algumas ferramentas e opções para uma gestão adequada de riscos na aplicação de insumos agrícolas foram apresentadas.

No caso da produção, este experimento apenas considerou o problema de corrigir a acidez do solo. No entanto, a metodologia é perfeitamente viável para outras estimativas relacionadas à abordagem da agricultura de precisão para colocação de insumos, desde que haja um modelo matemático definido e amostras pontuais com atributos numéricos disponíveis.

5.1 Trabalhos Futuros

Este trabalho apresentou uma metodologia para o planejador e tomador de decisão do setor agrícola que já trabalha com tecnologia de ponta na área através da agricultura de precisão. No entanto, não esgota as possibilidades de inovações, principalmente no que diz respeito ao estabelecimento de novas funções de custo e outras variáveis de produção.

Uma outra possibilidade diz respeito a modelar a covariância conjunta das variáveis relacionadas na modelagem espacial, através do procedimento de cokrigagem e avaliar o desempenho desta opção para a simulação conjunta, principalmente quando mais de duas variáveis estiverem envolvidas no processo.

Estabelecer valores limiares para avaliação de impactos e riscos é uma tarefa não muito simples, pois, os limiares servem de referência ou limites para determinar o que é aceitável ou tolerável em termos de impacto. Ou seja, nem sempre é possível determiná-los com precisão. Uma idéia é testar novos limiares para aplicações diferentes, por exemplo, para o uso de fertilizantes.

REFERÊNCIAS BIBLIOGRÁFICAS

- AERTS, J.C.J.H.; CLARKE, K.C.; KEUPER, A.D. Testing popular visualization techniques for representing model uncertainty. **Cartography and Geography Information Science**, v. 30, n. 3, p. 249-261, 2003.
- AERTS, J.C.J.H.; HEUVELINK, G.B.M.; GOODCHILD, M.F. Accounting for spatial uncertainty in optimization with spatial decision support systems. **Transactions in GIS**, v. 7, n. 2, p. 211-230, 2003.
- AGUMYA, A. HUNTER, G.J. Responding to the consequences of uncertainty in geographical data. **International Journal of Geographical Information Science**, v. 16, n. 5, p. 405-417, 2002.
- ANDRADE, E. L. **Introdução à pesquisa operacional: métodos e modelos para análise de decisão**. 2ª ed. Rio de Janeiro: LTC, 2000.
- ATKINSON, P. Geographical information science: geostatistics and uncertainty. **Progress in Physical Geography**, v. 23, n. 1, p. 134-142, 1999.
- BAZERMAN, M.H. **Processo decisório**. 5ª ed. [S.l.]: Editora Campus, 2002. 248p.
- BEN, J. R. **Adubação foliar na cultura da soja**. Passo Fundo: EMBRAPA-CNPT, 1983. 13 p
- BERNSTEIN, P.L. **Desafio aos deuses: a fascinante história do risco**. 18ª ed.. [S.l.]: Editora Campos, 1997. 389p.
- BOGNOLA, I.A.; POTTER, R.O .; CARVALHO, A .P.; FASOLO, P.J.; BHERING, S.B. MARTORANO, L.G. **Caracterização dos solos do município de Carambeí, PR**. Boletim de Pesquisa e Desenvolvimento 08, ISSN 1678-0884: Embrapa, Rio de Janeiro, 2002.
- BÖNISCH, S. **Geoprocessamento ambiental com tratamento de incerteza** : o caso do zoneamento pedoclimático para soja no estado de Santa Catarina. 2001-09. 251 p. (INPE-9474-TDI/824). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2001. Disponível em: <<http://urlib.net/sid.inpe.br/marciana/2003/02.26.11.04>>. Acesso em: 06 ago. 2006.
- BOURENNANE, H.; COUTURIER, D.K.A. Comparasion of kriging with external drift and simple linear regression for predicying soil horizon thickness with different sample densities. **Geoderma**, v. 97, p. 255-271, 2000.
- BURROUGH, P. A.; MCDONNELL , R.A. **Principles of geographical information systems**. New York: Oxford University Press, 1998. 344p.
- CAIRES, E. F.; BLUM J.; BARTH, G.; GARBUIO, F. J. E KUSMAN, M. T. Alterações químicas do solo e resposta da soja ao calcário e gesso aplicados na implantação do sistema plantio direto. **Revista Brasileira de Ciências do Solo**, v. 27, p. 275-286, 2003.

CAIRES, E.F.; LUIS R.F.; ALLEONI, M.A.; CAMBRI, B. and GABRIEL B. Surface application of lime for crop grain production under a no-till system. **Agronomy Journal**, v. 97, p. 791-798, may-june 2005.

CÂMARA, G. ET AL. **Anatomia de sistemas de informação geográfica**. [Sn]. [SI]: Escola de Computação, SBC, 1996.

CÂMARA, G. **Modelos, linguagens e arquiteturas para bancos de dados geográficos**. Dezembro 1995. 282 p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos. 1995.

CÂMARA, G.; MEDEIROS, J.S. de. Princípios Básicos em geoprocessamento. In: Eduardo Delgado Assad; Edson E. Sano. (Org.). **Sistemas de informações geográficas. aplicações na agricultura**. 2 ed. Brasília: EMBRAPA, 1998, v. p. 3-11.

CAMARGO, E. C. G. **Desenvolvimento, implementação e teste de procedimentos geoestatísticos (Krigagem) no sistema de processamento de informações georreferenciadas (SPRING)**. 1997-06. 146 p. (INPE-6410-TDI/620). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, Sao Jose dos Campos. 1997. Disponível em:

<<http://urlib.net/sid.inpe.br/iris@1912/2005/07.20.08.47.41>>. Acesso em: 12 abr. 2003.

CAMARGO, E. C. G. **Distribuição espacial do risco associado a eventos raros por geoestatística binominal e simulação condicionada**. 2007-03-29. 148 p. (INPE-14800-TDI/1243). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2007. Disponível em:

<<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/05.18.13.01>>. Acesso em: 12 abr. 2003.

CAMARGO, E.C.G.; DRUCK, S.; MONTEIRO, A.M.V.; FREITAS, C.C.; CÂMARA, G. Mapeamento do risco de homicídio com base na co-krigeagem binomial e simulação: um estudo de caso para São Paulo, Brasil. **Caderno de Saúde Pública**, v. 24, p. 1-16, 2008.

CATANI, R.A. e GALLO, J.R. Avaliação da exigência de calcário dos solos do estado de são paulo mediante a correlação entre o pH e saturação de bases. **Revista da Agricultura, Piracicaba**, v. 30, p. 49-60, 1955.

CENTRO DE TECNOLOGIA MINERAL (CETEM). **Calcário agrícola no Brasil**. Série Estudos e Documentos. 79p. MCT, 2003.

CHAI, X.; HUANG, Y.; YUAN, X. Accuracy and uncertainty of spatial patterns of soil organic matter. **Journal of Agricultural Research**, v. 50, p.1141-1148, 2007.

CRUZ, P.S. **Reservoir management decision-making in the presence of geological uncertainty**. 2000. 217p. (Degree of Doctor of Philosophy, PhD), Stanford University, March, 2000.

CRUZ, P.S.; HORNE, R.N.; DEUTSCH, C.V. The quality map: a tool for reservoir uncertainty quantification and decision making. **SPE**, n. 87642, 2004.

DAINESE, R. C.; ADAMI, M.; MOLIN, J. P.; MOREIRA, M. A. Uso do SPRING no processamento de dados de fertilidade do solo para uso em agricultura de precisão. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 51-58. ISBN 85-17-00017-X. Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2002/11.07.16.26>>. Acesso em: 16 dez. 2006.

DeANGELIS, D.L., PEARLSTINE, L., MAZZOTTI, F.J., BARNES, T., DUEVER, M., STARNES, J., 2004. Spatial decision support systems for landscape ecological evaluations in the southwest Florida feasibility study. **U.S. Department of the Interior, U.S. Geological Survey**, p. 2004–3113.

DEUTSCH, C.V.; JOURNEL, A.G. **GSLIB**: geostatistical software library and user's guide. New York: Oxford University Press, 1998. 369p, 1 CD.

DIGGLE, P. J. ; RIBEIRO JR, P. J. ; CHRISTENSEN, O. F. . **An introduction to model based geostatistics**. In: Jesper Möller. (Org.). Spatial statistics and computational methods. : Springer Verlag, 2003, v. 173, p. 43-46.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V.. **Análise espacial de dados geográficos**. São José dos Campos: INPE, 2002. Relação de todos os N° dos capitulos desse Livro: INPE-8556-PRE/4300 INPE-8557-PRE/4301 INPE-8560-PRE/4304 INPE-8561-PRE/4305 INPE-11443-PRE/6865 INPE-11444-PRE/6866. (INPE--/).

DRUCK, S.; FELGUEIRAS, C. A.; MONTEIRO, A. M. V. Análise espacial de superfícies: o enfoque da geoestatística por indicação. In: FUKS, Suzana Druck; CARVALHO, Marília Sá; CÂMARA, Gilberto; MONTEIRO, Antonio Miguel Vieira (Ed.). **Análise espacial de dados geográficos..** São José dos Campos: INPE, 2002. p. 25. (Acompanha CD-ROM INPE-8556-PRE/4300). (INPE-11444-PRE/6866). Disponível em: <<http://urlib.net/sid.inpe.br/sergio/2004/10.07.15.00>>. Acesso em: 07 ago. 2005.

EASTMAN, J.R.; EMANI, S.; STEPHANIE, H.; JOHNSON, A.; JIANG, H.; RAMACHANDRAN, M. **In: Applications of geographic information systems (GIS) technology in environmental risk assessment and management**, chapter 1. Jan. 1997.

EHRlich, P. J. Modelos quantitativos de apoio às decisões-I. **Revista de Administração de Empresas-FGV**, São Paulo, v.36, n.1, p.33-41, jan/fev/mar, 1996.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (Embrapa Soja). **Tecnologias de Produção na Região Central do Brasil**. Janeiro, 2003 Versão eletrônica disponível em (<http://sistemasdeproducao.cnptia.embrapa.br>). Acesso em: 12 out. 2006.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (Embrapa Solos). **Tecnologias de Produção na Região Central do Brasil**. Janeiro, 2004 Versão eletrônica disponível em (<http://sistemasdeproducao.cnptia.embrapa.br>). Acesso em: 13 mar. 2005.

ESRI. **Manual do usuário**, Disponível (www.ersri.com). Acesso em: 23 fev. 2008.

- EUROPIAN COMMISSION AGRICULTURE DIRECTORATE-GENERAL.
Directorate A. economic analyses, forward studies, evaluation. Risk management tools for EU agriculture with special focus on insurance. January, 2001. 84p.
- FAECHNER, T; NORRENA, K; THOMAS, A.G.; DEUTSCH, C.V. A risk-qualified approach to calculate locally varying herbicide application rates. **Weed Research**, v. 42, n. 6, p. 476-485, december, 2002.
- FAGEIRA, N.K. Efeito da calagem na produção de arroz, feijão, milho e soja em solo de cerrado. **Pesquisa Agropecuária Brasileira-PAB**, Brasília, v.36, n.11, p.1419-1424. 2001.
- FELGUEIRAS, C. A.; FUKS, S. D.; MONTEIRO, A. M. V. Classificação de atributos espaciais baseada em informação de incertezas. Uma metodologia de apoio a decisões. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 967-974. CD-ROM. ISBN 85-17-00017-X. Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2002/11.18.11.37>>. Acesso em: 26 ago. 2004.
- FELGUEIRAS, C. A. **Modelagem ambiental com tratamento de incertezas em sistemas de informação geográfica: o paradigma geoestatístico por indicação.** 1999-12-21. 212 p. (INPE-8180-TDI/760). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2000. Disponível em: <<http://urlib.net/sid.inpe.br/deise/2001/08.03.12.35>>. Acesso em: 01 set. 2004.
- FISHMAN, G.S., **Monte Carlo: Concepts, algorithms, and applications.** [sn]: Springer Verlag, New York. 1995.
- FONSECA, W. S. **Contribuição da simulação de Monte Carlo na projeção de cenários para gestão de custos na área de laticínios.** 2005. 137p. Dissertação de mestrado em Engenharia de Produção. Universidade Federal de Itajubá. Itajubá, MG. Dezembro, 2004.
- FUKUDA, C.; OTSUBO, A.A. Cultivos na Região Centro Sul do Brasil. **Embrapa Solos, sistema de produção**, Jan, 2003. ISSN 1678-8796. Disponível em: www.embrapa.br.
- GOODCHILD, M.F. Uncertainty in geospatial information, representation, analysis and decision support. Santa Bárbara, Califórnia. **Submitted by the National Center for Geographic Information and Analysis at the University of California, Santa Barbara and the University of Maine.** Disponível em: (www.spatial.maine.edu/~twindhol/nuri.html). Acesso em 15/07. 2001.
- GOOVAERTS P. & VAN MEIRVENNE M. **Delineation of hazardous areas and additional sampling strategy in presence of a location-specific threshold.** In: P. Monestiez, D. Allard & R. Froidevaux (eds.) *Geostatistics for Environmental Applications III.* Quantitative Geology and Geostatistics v. 11. Kluwer Academic Publishers, p. 125-136. ISBN : 0-7923-7107-0. 2001.
- GOOVAERTS, P. Geostatistical modelling of uncertainty in soil science. **Geoderma**, v. 103, p. 3-26, 2001.

- GOOVAERTS, P. **Geostatistics for natural resources evaluation**. [sn]: New York: Oxford University Press, 1997. 483p.
- GOOVAERTS, P.; JOURNAL, A.G. Integrating soil map information in modelling the spatial variation of continuous soil properties. **European Journal of Soil Science**, v.46, n.3, p.397-414, 1995.
- GUNERALP, B.; GERTNER, G.; MENDOZA, G.; ANDERSON, A. Evaluation probabilistic data with a possibilistic criterion in land restoration decision-making: effects on the precision of results. **Fuzzy sets and systems**: v. 158, p. 1546-1560, 2007.
- GUNERALP, B.; GERTNER, G.; MENDOZA, G.; ANDERSON, A. Spatial simulation and fuzzy threshold analyses for allocating restoration areas. **Trans. GIS 7**, p. 325-343, 2003.
- GUNNINK, J.L.; BURROUGH, P.A. Interactive spatial analysis of soil attribute patterns using exploratory data analysis and GIS. In: SPATIAL ANALYTICAL PERSPECTIVES ON GIS. **Proceedings...** Fisher, M.O; Scholten, H.J.; Unwin, D.. Great Britain: Taylor e Francis. Chapter 6. p.87-99. 1999.
- HARRIS, R. Introduction to decision making. **Technical report**. Versão de julho de 1998. Acesso em 25/04/2007 (<http://www.virtualsalt.com>). 15 p.
- HASTIE, R. Problem for judgment and decision making. **Annual Review of Psychology**, v. 52, p. 653-660, jan. 2001.
- HELTON, J.C.; DAVIS, F.J. Latin hypercube sampling and the propagation of uncertainty in analysis of complex systems. **Reliability Engineering and System Safety**, v. 81, p. 23-69, 2003.
- HEUVELINK, G.B.M. **Uncertainty propagation in GIS**. In: NCGIA Core Curriculum in Geographic Information Science; edited by Gary Hunter, Austrália.1999. Disponível em http://www.ncgia.ucsb.edu/giscc/units/u098/u098_f.html.) Acesso em 05/08/2004.)
- HEUWELINK, G. B. M. **Error propagation in environmental modeling with GIS**. Bristol: Taylor and Francis Inc, 1998. 127p.
- HEUVELINK, G.M.; BURROUGH, P.A. Developments in statistical approaches to spatial uncertainty and its propagation. **International Journal of Geographic Information Science**, v. 16, p. 111-330, 2002.
- HUNTER, G.J.; GOODCHILD, M.F. Dealing with error in spatial databases: a simple case study. **Photogrametric Engineering and Remote Sensing**, v. 61, p. 529-37, 1995.
- IMPAR - Consultoria e Assessoria Agrícola. 2005. Disponível em: <http://www.imparag.com.br>.
- ISAAKS, E. H; SRIVASTAVA, R.M. **An introduction to applied geostatistics**. [sn]: New York: Oxford University Press, 1989. 561p.
- ISAAKS, R.M. An application of geostatistical methods for risk analysis in reservoir management. **Society of Petroleum Engineers (SPE)**, v. 20608, p. 825-834, 1990.

JOURNEL, A.G. Fundamentals of geostatistics in five lessons. In: INTERNATIONAL GEOLOGICAL CONGRESS, 1989, Washington, D.C., **Short Course in Geology**. v 8. Washington: American Geophysical Union, 1989.

JUSTINIANO, P. **Introdução à teoria da decisão**. Apostila de Curso. Disponível em : (<http://www.est.ufpr.br/~paulojus/CE227/ce227/node4.html>). 2004.

KORNDÖRFER, G.H.; PEREIRA, H.S.; CAMARGO, M.S. **Silicatos de cálcio e magnésio na agricultura**. 3.ed. Uberlândia, GPSi/ICIAG/UFU - (Boletim Técnico, 1), 2004, 28 p.

KRIVORUCHO, K; CRAWFORD, C.A.G. Assessing the uncertainty resulting from geoprocessing operations. In: GIS AND MODELLING WORKSHOP. **Proceedings...** Redlans, California. USA. Sep. 2003.

LAMPARELLI, R.A.C.; ROCHA, J.V. Agricultura de precisão: maior produtividade e menor custo. **Revista Agrosoft**, v.1, n.1. p.23-25, 1997.

LARK, R.M.; FERGUSON, R.B. Mapping risk of soil nutrient deficiency or excess by disjunctive and indicator kriging. **Geoderma**, v. 118, n. 1-2, p. 39-53, Jan. 2004.

LIMA, C.J.T. **Projeto de tomada de decisão em projetos de exploração e produção de petróleo no Brasil**: uma abordagem utilizando conjuntos nebulosos. . 2003.

Dissertação (Mestrado em Planejamento Energético) – Universidade Federal do Rio de Janeiro, Rio de Janeiro. out., 2003.

LOBATO, D.C.; **Proposta de um ambiente de simulação e aprendizado inteligente para RAID**. 2000. 167p. Dissertação de Mestrado - USP, São Carlos, SP. Abril, 2000.

LOPES, A .S. Acidez do solo e calagem. associação nacional para difusão de adubos. **Boletim técnico**, n.1., São Paulo, 1991.

MALCZEWSKI, J. Spatial decision support systems. NCGGIA core curriculum in geographic information science, unit 127. Canadá, **University of Western Ontario**. 1999. Disponível em (<http://www.ncgia.ucsb.edu/giscc/units/u127/u127.html>.) Acesso em 05/09/2004.

MANZATTO, C. V.; BHERING, S. B.; SIMÕES, M. **Agricultura de precisão**: propostas e ações da Embrapa solos. (<http://www.cnps.embrapa.br/search/pesqs/proj01/proj01.html>). Data de publicação no site: 18/03/1999.

MARTIN, N.B.; OTANI, M.N.; SERRA, R.; ÂNGELO, J.A. Subsídios para elaboração de plano diretor agrícola municipal. **Informações Econômicas**. São Paulo, v.28, n.4, p.33-45, abr. 1998.

MATHERON, G. **The theory of regionalized variables and its applications**. Paris: Les Cahiers du Centre de Morphologie Mathématique de Fontainebleu, 1971, 211 p.

McBRATNEY, A.B. On variation, uncertainty and informatics in environmental soil management. **Australian Journal of Soil Research**, v. 30, n. 9, p. 13-35, 2001.

- McBRATNEY, A.B.; Whelan, B.M.; Shatar, T.M. Variability and uncertainty in spatial, temporal and spatiotemporal crop-yield and related data. In: CIBA FOUNDATION SYMPOSIUM, 1997, Wiley Chichester. **Proceedings...** Wiley Chichester, 1997. p. 141-160.
- METROPOLIS N. and ULAM S. "The Monte Carlo Method", **Journal of the American Statistical Association**, v. 44, n. 247, p. 335–341, 1949. ([doi:10.2307/2280232](https://doi.org/10.2307/2280232))
- MINASNY, B.; McBRATNEY, A.B. Uncertainty analysis for pedotransfer functions. **European Journal of soil science**, v. 53, p. 417-429, Sept., 2002.
- MIRANDA, L.N.; de MIRANDA, J.C.C.; REIN, T.A; GOMES, A.C. Utilização de Calcário em Plantio Direto e Convencional de Soja e Milho em Latossolo Vermelho. **PAB**, Brasília, v.40, n. 6, p. 563-572, 2005.
- MORON, M. A. M. **Concepção, desenvolvimento e validação de instrumentos de coleta de dados para estudar a percepção do processo decisório e as diferenças culturais**. 1998. 238p. Porto Alegre, Dissertação de Mestrado, PPGA-UFRGS,1998.
- MOWRER, H. T. and CONGALTON, R. G. (2000). **Quantifying spatial uncertainty in natural resources: theory and applications for GIS and remote sensing**. Chelsea, Mich., Ann Arbor Press. Hodges Library / Stacks: G70.212.Q83. 2000
- MYERS, J.C. **Geostatistical error management: quantifying uncertainty for environmental sampling and mapping**. [sn]: New York: Van Nostrand Reinhold, 1997. 571p.
- NARULA, K.K.; BANSAL, N.K.; GOSAIN, A.K.; WENDLAND, F. Gis based identification of risk to nutrient exposure in the large agricultural lands of India-towards better decision making. **Journal of Geographic Information and Decision Analysis.**, v. 6, n. 2, p. 82-94, 2002.
- NETER, J.; KUTNER, M.H.; NACHTSHEIM, M.H.; WASSERMAN, W. **Applied linear statistical models**. 4. [SI]: McGraw-Hill, 1996.
- NEVES, M. C.; RAMOS, F. R.; CAMARGO, E. G.; CÂMARA, G.; MONTEIRO, A. M. V. Análise exploratória espacial de dados sócio-econômicos de São Paulo. In: GISBRASIL, 2000, Salvador, BR. 2000. CD-ROM. (INPE-8537-PRE/4283).
- NOLLA, A.; SCHLINDWEIN, J.A.; AMARAL, A.S.; ANGHINONI, I. Indicadores para tomada de decisão de calagem no sistema de plantio direto. **Revista Brasileira de Agrociências**, Pelotas, v.11, n.4, p.471-476, out.-dez. 2005.
- NUNES, L. M. **Inferência geoestatística** - Cap. 4. Departamento de Ambiente e Ciências da Terra, Universidade do Algarve, Portugal. 2003. Disponível em: (http://w3.ualg.pt/~nunes/Pessoal/LuisNunes_Texto). Acesso em: maio, 2004.
- NUNES, L. M.; SOUSA, A. J.; MUGE, F.H. The use of remote sensing imagery to update forest cover. In: GEOSTATS 2000. **Proceedings...** 2000, South Africa. Edited by W. J. Klingeld and D.G. Krige. 2000.

- OLIVEIRA, C. P. M.; ONO, S.; JUNIOR M.; VIEIRA A.; PORTO, R. L.. Sistema de Suporte a decisão para modelagem e previsão de cheias para a bacia do alto tietê utilizando o modelo SMAP diário. **Anais da Associação Brasileira de Recursos Hídricos**. Porto Alegre – RS : ABRH, 2006.
- OLIVEIRA, E.L.; PAVAN, M.A. Control of soil acidity in no-tillage system for soybean production. **Soil & Tillage Research**, Amsterdam, v.38, p.47-57, 1996.
- ORTIZ, J.L. **Emprego do geoprocessamento no estudo da relação entre potencial produtivo de um povoamento de eucalipto e atributos do solo e do relevo**. 2003. Dissertação (Mestre em Recursos Florestais). ESALQ/USP. Piracicaba, SP, 2003.
- ORTIZ, J. O.; FELGUEIRAS, C. A.; DRUCK, S.; MONTEIRO, A. M. V. **Avaliação do procedimento geoestatístico de cokrigagem para determinação da distribuição espacial de propriedades de solos**. São José dos Campos: INPE, 2004-07-09. (INPE ePrint sid.inpe.br/yolanda/2004/07.08.08.38). Disponível em: <<http://urlib.net/sid.inpe.br/yolanda/2004/07.08.08.38>>. Acesso em: 28 ago. 2008.
- ORTIZ, J.O.; FELGUEIRAS, C.A.; DRUCK, S.; MONTEIRO, A.M.V. Modelagem de fertilidade do solo por simulação estocástica com tratamento de incertezas. **Pesquisa Agropecuária Brasileira-PAB**, Brasília, v.39. n.4, p.379-389, 2004.
- PAGLIS, C.M. **Informática na agricultura**. Lavras, Minas Gerais: Universidade Federal de Lavras (UFLA), 2002. Curso de Agronomia. (http://www.dag.ufla.br/MODAGP/private/Informatica_na_agricultura_2000.pdf).
- PEARLSTINE, L.G.; MAZZOTTI, F.J.; DeANGELIS, D.L. A review of spatially explicit support systems for landscape ecosystem assessment and restoration. **U. S. Geological Survey**, 2004. Disponível em: (<http://www.pubs.USGS.gov/fs/2004/3113/>).. Acesso em: jun., 2007.
- PEBESMA, E.J.; HEUVELINK, G.B.M. Latin hypercube sampling of gaussian random fields. **Technometrics**, v. 41, n. 4, p. 303-312, Nov., 1999.
- PEBESMA, E.J.; HEUVELINK, G.B.M.; KROS, J. ., Error assessment in a soil acidification modelling study: efficiency issues and change of support.. In: INTERNATIONAL SYMPOSIUM ON SPATIAL ACCURACY ASSESSMENT IN NATURAL RESOURCES AND ENVIRONMENTAL SCIENCES, 4., 2000, Amsterdam. **Proceedings...** Amsterdam: Delft University Press, 2000. p. 521-528.
- PEREZ, V.S.; JOURNAL, A.G. Indicator principal component kriging. **Mathematical Geology**, v. 23, n. 5, p. 759-793, 1991.
- PITTA, G.V.; COELHO, A M.; ALVES, V.M.C.; FRANÇA, G.E.; MAGALHÃES, J.V. Cultivo do milho. **Embrapa sorgo e milho**, 2006. ISSN 1679-012. 2006. Disponível em (<http://www.cnpms.embrapa.br/publicacoes/milho/fercalagem.htm>).
- PONTIFÍCIA UNIVERSIDADE CATÓLICA (PUC). **Base teórica do método de monte Carlo**. Rio de Janeiro, 2007.. Certificação digital no 0312527/CA. 2007. Disponível em: (http://www.maxwell.lambda.ele.puc-rio.br/cgi-bin/PRG_0599.EXE/8675_6.PDF).

QSP – CENTRO DA QUALIDADE, SEGURANÇA E PRODUTIVIDADE PARA O BRASIL E AMÉRICA LATINA. **Gestão de Riscos – A norma AS/NZS 4360:2004.** – São Paulo: Risk Tecnologia Editora, 2004.

QUAGGIO J. A. **Manejo da acidez do solo e a prática da calagem: acidez e calagem em solos tropicais.** Campinas-SP: Instituto Agronômico, 2004. Artigo técnico da Calpar-calcário agrícola. Disponível em: (<http://www.calpar.com.br/artigos.html>).

QUAGGIO, J.A **Critérios para calagem em solos do Estado de São Paulo.** Tese de Mestrado, ESALQ, Piracicaba, 1983. 76p.

QUAGGIO, J.A; FERREIRA, C.R.R.P.T.; SANTOS, Z.P.S. Calcário agrícola no estado de são paulo: consumo, preços e estrutura de produção e distribuição. **Informações Econômicas**, São Paulo, v.26, n.8, Agosto, 1996.

RAFAELI NETO, S.L. **Um modelo de sistema de apoio à decisão especial para gestão de desastres por inundação.** Tese de doutorado. USP. São Paulo. 2000.

RAFAELI NETO, S.L.R. Uma Estrutura Conceitual para Análise e Solução de Problemas Espaciais em Geoprocessamento. **Revista de Ciências Agro-veterinárias**, v.2, n.1, p.1-29, 2003.

RAFAELI NETO, S.L.R. A conceptual framework for analysis and solution of spatial problems in geoprocessing field. **Revista de Ciências Agro-veterinárias**, p.19-26, 2004.

RAHEJA, N. GIS-based software applications for environmental risk management. In: MAP INDIA CONFERENCE, 2003, Map India. **Proceedings...** Map Índia, 2003. Disponível em: The Geospatial Resource Portal, www.GISdevelopment.net.

RAIJ, B.V. **Fertilidade do solo e adubação.** São Paulo: Ceres, 1991. 343p.

RAIJ, BERNARDO VAN; CANTARELLA, H.; ZULLO, M. A. T. O método tampão SMP para determinação da necessidade de calagem em solo do Estado de São Paulo. **Bragantia**, v. 38, p. 57-69, 1979.

RICHARDS, J.A **Remote sensing digital Image analysis: an introduction.** Berlin: Springer-verlag, chapter 6, 1996. 280p.

RODRIGUES, J.B.T. **Variabilidade espacial e correlações entre atributos de solo e produtividade na agricultura de precisão.** Dissertação apresentada à Faculdade de Ciências Agronômicas da UNESP – Campus de Botucatu, para a obtenção do título de Mestre em Agronomia – Área de Concentração em Energia na Agricultura. Janeiro, 2002.

ROSA, U.B. **Estimativa de calagem pelo método smp para alguns solos do paraná.** Dissertação de mestrado em Ciência do solo – Universidade Federal do Paraná. Curitiba, 2006.

SAGE, A. **Decision support systems engineering.** New York: Willey & Sons, 1991. 344p.

- SAITO, H.; GOOVAERTS, P. Accounting for measurement error in uncertainty modelling and decision-making using kriging and p-field simulation: application to dioxin contaminated site. **Environmetrics**, v. 13, p. 555-567, 2002.
- SALIBY, E.; ARAÚJO, MARCOS M. S. Cálculo do valor em risco através da simulação de Monte Carlo: uma avaliação de uso de métodos amostrais mais eficientes em portfólios com opções. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 23., 2001, Campos do Jordão. **Anais...** Rio de Janeiro: Sociedade Brasileira de Pesquisa Operacional, 2001. Disponível em (<http://www.sobrapo.org.br/simposios/xxxiii/artigos/080-ST280.pdf>).
- SANTOS, A C.; Ferreira, D.F.; Definição do tamanho amostral utilizando simulação de monte Carlo. **Revista de Ciências, Lavras**, v.27, n.2, pp.432-437, mar/abr, 2003.
- SEARCY, S.W. Precision farming: A new approach to crop management. **Texas Agricultural Extension Service**. The Texas A&M University System, 1997. p.4. Disponível na Internet. (<http://agpublications.tamu.edu/pubs/eengine/15177>). pdf em 22 Mar. 2000.
- SILVEIRA, C.M.R.; Passos, A.C. **A incerteza e a tomada de decisão no âmbito do jogo das empresas**. Disponível em: (<http://www.clovis.massaud.nom.br/artigos>). Acesso em 20/10/2004.
- SIQUEIRA, J.O. **Risco**: da filosofia à administração. Faculdade de Economia, Administração e Contabilidade (FEA); USP, São Paulo, SP. 2004. (<http://www.fia.com.br/professores/siqueira>).
- SOARES, A. Geoestatística para ciências da terra e do ambiente. Lisboa: **IST Press**. 2000. 206p.
- SOARES, C.D.V. Um sistema de apoio ao planejamento energético da operação de sistemas de energia elétrica. In: SIMPOSIO BRASILEIRO DE PESQUISA OPERACIONAL (SBPO), 1993, Campinas. **Anais...** Campinas, SP: [s.n], p.147-149, Nov.1993.
- SOUZA, D.; LOBATO, E. **CERRADO: Correção do solo e adubação**. 2. ed. Brasília: Embrapa informação tecnológica, 2004. 416p.
- Stein, A.; Hoogerwerf, M.; Bouma, J. Use of soilmap delineations to improve co-kriging of point data on moisture deficits. **Geoderma**, v. 43, p. 163-177, 1998.
- TAYLOR, K.; WALKER, G.; ABEL, D.A. A framework for model integration in spatial decision support systems. **International Journal of Geographical Information Sciences**, v. 13, p. 533-555, 1999.
- THAYER, W.C.; GRIFFITH, D.A.; GOODRUM, P.E.; DIAMOND, G.L.; HASSETT, J.M. Application of geostatistics to risk assessment. **Risk Analysis**, v. 23, n. 5, p. 945-960, oct. 2003.
- TONETTO, L.M.; KALIL, L.L.; MELO, W.V.; SCHNEIDER, D.G.; STEIN, L.M. **O papel das heurísticas no julgamento e tomada de decisão sob incerteza**, 2004. Disponível em : ([http://professores.faccat.br/melo/Julgamento e Tomada de Decisao.doc](http://professores.faccat.br/melo/Julgamento_e_Tomada_de_Decisao.doc)).

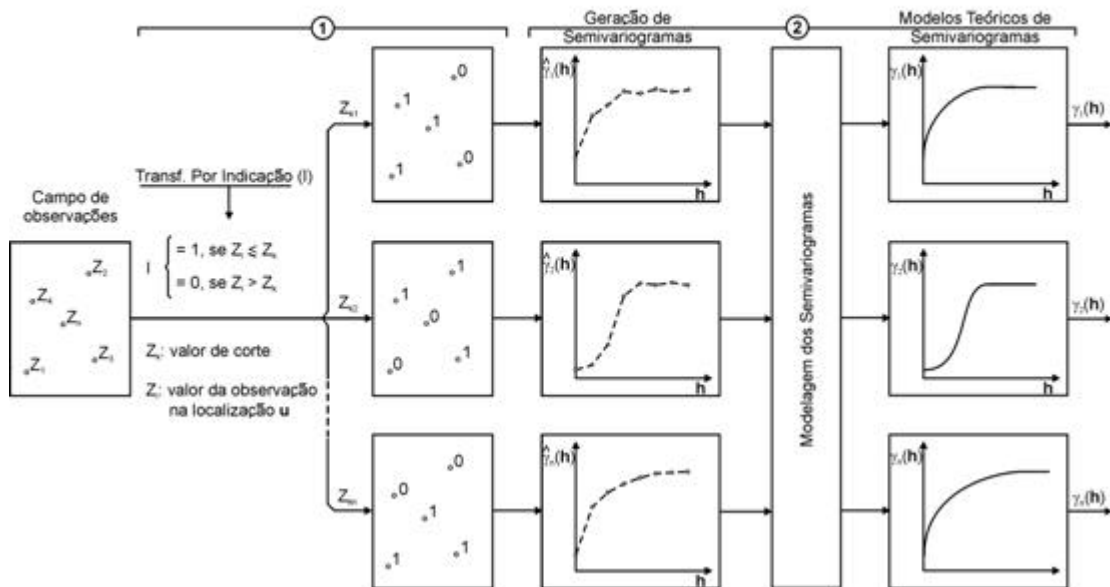
- TSCHIEDEL, M; FERREIRA, M.F. Introduction the precision Farming: Concepts and Advantages. **Ciencia Rural**, v.32, n.1, Santa Maria, jan./feb. 2005.
- VANN, J.; BERTOLI, O.; JACKSON, S. An Overview of Geostatistical Simulation for Quantifying Risk. In: ASSOCIATION OF AUSTRALASIA SYMPOSIUM QUANTIFYING RISK AND ERROR, 2002. [S.l.]. **Proceedings...** [S.l.; s.n.], 2002. p. 1-12.
- VETTORAZZI, C.A.; FERRAZ, S.F.B. **Silvicultura de precisão: uma nova perspectiva para o gerenciamento de atividades florestais.** In: Borém, A.; Giudice, M.P.; Queiróz, D.M. de; et al. (Ed.). *Agricultura de Precisão. Viçosa: Os autores, 2000. p. 65-75.*
- VISCARRA ROSSEL, A.R.; GOOVAERTS, P.; McBRATNEY, A.B. Assessment of the production and economic risks of site-specific liming using geostatistical uncertainty modeling. **Environmetrics**, v. 12, p. 699-711, 2001.
- VISCARRA ROSSEL, R.A.; McBRATNEY, A.B. A response surface calibration model for rapid and versatile site specific lime requirement predictions in south eastern Australia. **Australian Journal of Soil Research**, v. 39, p. 185-210, 2001.
- WACKERNAGEL, H. **Multivariate geostatistics.** New York: Springer, 1998. 291p.
- WILMOT, R.D. **Development of a quantitative framework for regulatory risk assessments: probabilistic approach.** [S.l.]: SKI, n. 41, Nov. 2003. SKI Report.
- WINDHOLZ, T.K. **Strategies for handling spatial uncertainty due to discretization.** 2001. 133p Doctor Philosophy thesis. University of Maine; May, 2001.
- ZHANG, J.; GOODCHILD, M. **Uncertainty in Geographical information.** London Press: Taylor and Francis, 2002.

APÊNDICE A

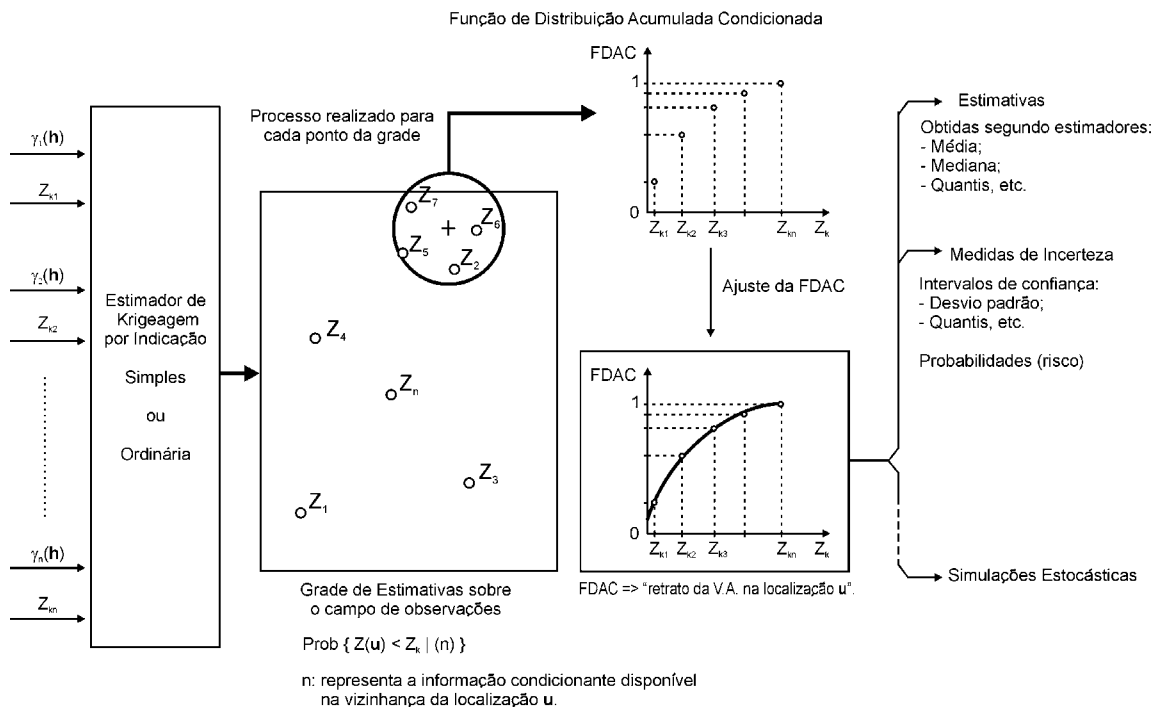
Processo de Krigeagem por Indicação para Atributos Contínuos

Primeira Etapa do Processo de Krigeagem por Indicação para atributos contínuos

- ① - Codificação Probabilística dos Dados => Função de Transformação por Indicação
- ② - Análise Estrutural => Função Semivariograma por Indicação e Modelagem



Segunda Etapa do Processo de Krigeagem por Indicação para atributos contínuos



APÊNDICE B

Descrição das Amostras

NÚMERO DA AMOSTRA	CÓDIGO DO TALHÃO	COORDENADAS		PROPRIEDADES	
		X	Y	CTC	V %
38	05 12ab 13ab 38	-50.30	-24.90	178.50	64.00
39	05 12ab 13ab 39	-50.31	-24.90	149.80	57.00
40	05 12ab 13ab 40	-50.31	-24.90	150.20	61.00
41	05 12ab 13ab 41	-50.31	-24.90	147.30	57.00
42	05 12ab 13ab 42	-50.31	-24.90	142.30	44.00
43	05 12ab 13ab 43	-50.31	-24.90	147.00	56.00
44	05 12ab 13ab 44	-50.31	-24.90	176.00	50.00
45	05 12ab 13ab 45	-50.31	-24.90	156.70	59.00
46	05 12ab 13ab 46	-50.31	-24.90	184.70	61.00
47	05 12ab 13ab 47	-50.31	-24.90	183.80	47.00
48	05 12ab 13ab 48	-50.31	-24.90	190.50	54.00
50	05 12ab 13ab 50	-50.31	-24.90	166.50	41.00
51	05 12ab 13ab 51	-50.31	-24.90	192.80	49.00
52	05 12ab 13ab 52	-50.31	-24.90	138.40	42.00
53	05 12ab 13ab 53	-50.31	-24.90	135.00	47.00
54	05 12ab 13ab 54	-50.31	-24.90	159.10	64.00
55	05 12ab 13ab 55	-50.31	-24.90	189.60	43.00
56	05 12ab 13ab 56	-50.31	-24.90	131.30	64.00
57	05 12ab 13ab 57	-50.31	-24.90	131.20	45.00
58	05 12ab 13ab 58	-50.31	-24.89	124.60	49.00
59	05 12ab 13ab 59	-50.31	-24.90	123.30	66.00
60	05 12ab 13ab 60	-50.32	-24.90	150.20	61.00
61	05 12ab 13ab 61	-50.31	-24.89	130.50	39.00
62	05 12ab 13ab 62	-50.32	-24.89	156.20	54.00
63	05 12ab 13ab 63	-50.32	-24.89	170.30	53.00
64	05 12ab 13ab 64	-50.32	-24.89	158.10	38.00
1	05 16 01	-50.31	-24.89	144.90	64.00
2	05 16 02	-50.31	-24.89	122.80	41.00
3	05 16 03	-50.31	-24.89	125.90	43.00
4	05 16 04	-50.31	-24.89	125.10	36.00
5	05 16 05	-50.31	-24.89	179.40	64.00
6	05 16 06	-50.31	-24.89	113.10	43.00
7	05 16 07	-50.31	-24.89	145.10	60.00
8	05 16 08	-50.31	-24.89	147.20	51.00
9	05 16 09	-50.31	-24.89	149.60	52.00
10	05 16 10	-50.30	-24.89	131.90	56.00
11	05 16 11	-50.30	-24.90	133.60	52.00
12	05 16 12	-50.30	-24.90	120.00	52.00
15	05 16 15	-50.30	-24.90	119.70	57.00
16	05 16 16	-50.30	-24.89	192.20	58.00
17	05 16 17	-50.30	-24.89	89.80	35.00
18	05 16 18	-50.30	-24.89	107.90	41.00
19	05 16 19	-50.30	-24.89	122.80	48.00
20	05 16 20	-50.31	-24.89	133.20	40.00
21	05 16 21	-50.31	-24.89	119.00	39.00
22	05 16 22	-50.31	-24.89	130.70	45.00
23	05 16 23	-50.31	-24.89	117.60	32.00
24	05 16 24	-50.31	-24.89	110.20	27.00
25	05 16 25	-50.31	-24.89	114.20	30.00
26	05 16 26	-50.31	-24.89	132.50	40.00
27	05 16 27	-50.31	-24.89	113.00	36.00
28	05 16 28	-50.31	-24.89	118.00	46.00
29	05 16 29	-50.31	-24.89	112.90	29.00

NÚMERO DA AMOSTRA	CÓDIGO DO TALHÃO	COORDENADAS		PROPRIEDADES	
		X	Y	CTC	V %
30	05 16 30	-50.31	-24.89	117.30	32.00
32	05 16 32	-50.31	-24.89	118.80	39.00
33	05 16 33	-50.31	-24.89	123.10	20.00
34	05 16 34	-50.31	-24.89	124.10	62.00
36	05 16 36	-50.31	-24.89	174.70	54.00
37	05 16 37	-50.30	-24.89	124.30	29.00
38	05 16 38	-50.30	-24.89	132.20	56.00
39	05 16 39	-50.30	-24.89	112.40	22.00
40	05 16 40	-50.30	-24.89	112.40	48.00
41	05 16 41	-50.30	-24.89	122.50	41.00
42	05 16 42	-50.30	-24.90	104.70	31.00
43	05 16 43	-50.30	-24.89	101.20	37.00
44	05 16 44	-50.30	-24.89	120.70	27.00
45	05 16 45	-50.30	-24.89	120.30	27.00
47	05 16 47	-50.30	-24.89	152.20	36.00
49	05 16 49	-50.31	-24.89	124.10	42.00
50	05 16 50	-50.31	-24.89	117.20	32.00
51	05 16 51	-50.31	-24.89	112.30	36.00
52	05 16 52	-50.31	-24.89	120.50	27.00
53	05 16 53	-50.31	-24.89	120.50	27.00
54	05 16 54	-50.31	-24.88	106.70	33.00
55	05 16 55	-50.31	-24.88	115.80	31.00
56	05 16 56	-50.31	-24.88	96.40	40.00
57	05 16 57	-50.31	-24.88	151.80	53.00
58	05 16 58	-50.31	-24.88	123.90	42.00
59	05 16 59	-50.31	-24.88	102.40	30.00
60	05 16 60	-50.31	-24.88	99.60	36.00
5	05 FIB 05	-50.31	-24.88	118.90	46.00
9	05 FIB 09	-50.31	-24.89	177.30	50.00
10	05 FIB 10	-50.31	-24.88	124.20	36.00
11	05 FIB 11	-50.31	-24.88	129.20	55.00
12	05 FIB 12	-50.31	-24.88	103.50	44.00
13	05 FIB 13	-50.31	-24.88	106.50	51.00
15	05 FIB 15	-50.31	-24.88	96.80	51.00
16	05 FIB 16	-50.31	-24.88	102.60	49.00
17	05 FIB 17	-50.31	-24.88	125.30	54.00
18	05 FIB 18	-50.31	-24.88	98.60	47.00
19	05 FIB 19	-50.31	-24.88	94.30	50.00
20	05 FIB 20	-50.31	-24.88	88.40	41.00
21	05 FIB 21	-50.31	-24.88	98.30	47.00
22	05 FIB 22	-50.31	-24.88	106.00	32.00
23	05 FIB 23	-50.31	-24.88	105.50	39.00
24	05 FIB 24	-50.31	-24.88	89.10	42.00
25	05 FIB 25	-50.31	-24.88	98.10	35.00
26	05 FIB 26	-50.31	-24.88	79.90	35.00
27	05 FIB 27	-50.31	-24.88	100.70	29.00
28	05 FIB 28	-50.31	-24.88	112.60	36.00
29	05 FIB 29	-50.31	-24.88	97.90	35.00
31	05 FIB 31	-50.31	-24.88	111.90	36.00
32	05 FIB 32	-50.31	-24.88	99.10	27.00
34	05 FIB 34	-50.31	-24.87	162.10	46.00
35	05 FIB 35	-50.31	-24.87	174.80	59.00
36	05 FIB 36	-50.31	-24.88	195.60	38.00

APÊNDICE C

Transformação para o Espaço das Principais Componentes

CTC	V	CTC	V	X-Mt		X-M	X-M*X-Mt	
178.5	64	178.5	64	48.44811	19.83019	48.44811	2347.22	960.7352
149.8	57					19.83019	960.7352	393.2364
150.2	61	149.8	57	19.74811	12.83019	19.74811	389.988	253.372
147.3	57					12.83019	253.372	164.6137
142.3	44	150.2	61	20.14811	16.83019	20.14811	405.9465	339.0965
147	56					16.83019	339.0965	283.2553
176	50	147.3	57	17.24811	12.83019	17.24811	297.4974	221.2965
156.7	59					12.83019	221.2965	164.6137
184.7	61	142.3	44	12.24811	-0.16981	12.24811	150.0163	-2.07987
183.8	47					-0.16981	-2.07987	0.028836
190.5	54	147	56	16.94811	11.83019	16.94811	287.2385	200.4994
166.5	41					11.83019	200.4994	139.9534
192.8	49	176	50	45.94811	5.830189	45.94811	2111.229	267.8862
138.4	42					5.830189	267.8862	33.9911
135	47	156.7	59	26.64811	14.83019	26.64811	710.1219	395.1965
159.1	64					14.83019	395.1965	219.9345
189.6	43	184.7	61	54.64811	16.83019	54.64811	2986.416	919.7381
131.3	64					16.83019	919.7381	283.2553
131.2	45	183.8	47	53.74811	2.830189	53.74811	2888.86	152.1173
124.6	49					2.830189	152.1173	8.009968
123.3	66	190.5	54	60.44811	9.830189	60.44811	3653.974	594.2164
150.2	61					9.830189	594.2164	96.63261
130.5	39	166.5	41	36.44811	-3.16981	36.44811	1328.465	-115.534
156.2	54					-3.16981	-115.534	10.0477
170.3	53	192.8	49	62.74811	4.830189	62.74811	3937.326	303.0852
158.1	38					4.830189	303.0852	23.33072
144.9	64	138.4	42	8.348113	-2.16981	8.348113	69.69099	-18.1138
122.8	41					-2.16981	-18.1138	4.708081
125.9	43	135	47	4.948113	2.830189	4.948113	24.48382	14.00409
125.1	36					2.830189	14.00409	8.009968
179.4	64	159.1	64	29.04811	19.83019	29.04811	843.7929	576.0296
113.1	43					19.83019	576.0296	393.2364
145.1	60	189.6	43	59.54811	-1.16981	59.54811	3545.978	-69.6601
147.2	51					-1.16981	-69.6601	1.368459
149.6	52	131.3	64	1.248113	19.83019	1.248113	1.557787	24.75032
131.9	56					19.83019	24.75032	393.2364
133.6	52	131.2	45	1.148113	0.830189	1.148113	1.318164	0.953151
120	52					0.830189	0.953151	0.689213
119.7	57	124.6	49	-5.45189	4.830189	-5.45189	29.72307	-26.3336
192.2	58					4.830189	-26.3336	23.33072
89.8	35	123.3	66	-6.75189	21.83019	-6.75189	45.58798	-147.395
107.9	41					21.83019	-147.395	476.5571
122.8	48	150.2	61	20.14811	16.83019	20.14811	405.9465	339.0965
133.2	40					16.83019	339.0965	283.2553
119	39	130.5	39	0.448113	-5.16981	0.448113	0.200805	-2.31666
130.7	45					-5.16981	-2.31666	26.72695
117.6	32	156.2	54	26.14811	9.830189	26.14811	683.7238	257.0409
110.2	27					9.830189	257.0409	96.63261
114.2	30	170.3	53	40.24811	8.830189	40.24811	1619.911	355.3984
132.5	40					8.830189	355.3984	77.97223
113	36	158.1	38	28.04811	-6.16981	28.04811	786.6967	-173.052
118	46					-6.16981	-173.052	38.06657

CTC	V	CTC	V	X-Mt		X-M	X-M*X-Mt	
112.9	29	144.9	64	14.84811	19.83019	14.84811	220.4665	294.4409
117.3	32					19.83019	294.4409	393.2364
118.8	39	122.8	41	-7.25189	-3.16981	-7.25189	52.58986	22.98711
123.1	20					-3.16981	22.98711	10.0477
124.1	62	125.9	43	-4.15189	-1.16981	-4.15189	17.23816	4.856924
174.7	54					-1.16981	4.856924	1.368459
124.3	29	125.1	36	-4.95189	-8.16981	-4.95189	24.52118	40.45598
132.2	56					-8.16981	40.45598	66.74582
112.4	22	179.4	64	49.34811	19.83019	49.34811	2435.236	978.5824
112.4	48					19.83019	978.5824	393.2364
122.5	41	113.1	43	-16.9519	-1.16981	-16.9519	287.3665	19.83051
104.7	31					-1.16981	19.83051	1.368459
101.2	37	145.1	60	15.04811	15.83019	15.04811	226.4457	238.2145
120.7	27					15.83019	238.2145	250.5949
120.3	27	147.2	51	17.14811	6.830189	17.14811	294.0578	117.1248
152.2	36					6.830189	117.1248	46.65148
124.1	42	149.6	52	19.54811	7.830189	19.54811	382.1287	153.0654
117.2	32					7.830189	153.0654	61.31185
112.3	36	131.9	56	1.848113	11.83019	1.848113	3.415522	21.86353
120.5	27					11.83019	21.86353	139.9534
120.5	27	133.6	52	3.548113	7.830189	3.548113	12.58911	27.7824
106.7	33					7.830189	27.7824	61.31185
115.8	31	120	52	-10.0519	7.830189	-10.0519	101.0404	-78.7082
96.4	40					7.830189	-78.7082	61.31185
151.8	53	119.7	57	-10.3519	12.83019	-10.3519	107.1616	-132.817
123.9	42					12.83019	-132.817	164.6137
102.4	30	192.2	58	62.14811	13.83019	62.14811	3862.388	859.5201
99.6	36					13.83019	859.5201	191.2741
118.9	46	89.8	35	-40.2519	-9.16981	-40.2519	1620.214	369.1022
177.3	50					-9.16981	369.1022	84.08544
124.2	36	107.9	41	-22.1519	-3.16981	-22.1519	490.7061	70.2173
129.2	55					-3.16981	70.2173	10.0477
103.5	44	122.8	48	-7.25189	3.830189	-7.25189	52.58986	-27.7761
106.5	51					3.830189	-27.7761	14.67035
96.8	51	133.2	40	3.148113	-4.16981	3.148113	9.910617	-13.127
102.6	49					-4.16981	-13.127	17.38733
125.3	54	119	39	-11.0519	-5.16981	-11.0519	122.1442	57.13617
98.6	47					-5.16981	57.13617	26.72695
94.3	50	130.7	45	0.648113	0.830189	0.648113	0.420051	0.538056
88.4	41					0.830189	0.538056	0.689213
98.3	47	117.6	32	-12.4519	-12.1698	-12.4519	155.0495	151.5371
106	32					-12.1698	151.5371	148.1043
105.5	39	110.2	27	-19.8519	-17.1698	-19.8519	394.0974	340.8532
89.1	42					-17.1698	340.8532	294.8024
98.1	35	114.2	30	-15.8519	-14.1698	-15.8519	251.2823	224.6182
79.9	35					-14.1698	224.6182	200.7836
100.7	29	132.5	40	2.448113	-4.16981	2.448113	5.993258	-10.2082
112.6	36					-4.16981	-10.2082	17.38733
97.9	35	113	36	-17.0519	-8.16981	-17.0519	290.7668	139.3107
111.9	36					-8.16981	139.3107	66.74582
99.1	27	118	46	-12.0519	1.830189	-12.0519	145.248	-22.0572
162.1	46					1.830189	-22.0572	3.349591
174.8	59	112.9	29	-17.1519	-15.1698	-17.1519	294.1872	260.1909
195.6	38					-15.1698	260.1909	230.1232

CTC	V	X-Mt		X-M	X-M*X-Mt	
117.3	32	-12.7519	-12.1698	-12.7519	162.6106	155.1881
				-12.1698	155.1881	148.1043
118.8	39	-11.2519	-5.16981	-11.2519	126.605	58.17013
				-5.16981	58.17013	26.72695
123.1	20	-6.95189	-24.1698	-6.95189	48.32873	168.0258
				-24.1698	168.0258	584.1798
124.1	62	-5.95189	17.83019	-5.95189	35.42496	-106.123
				17.83019	-106.123	317.9156
174.7	54	44.64811	9.830189	44.64811	1993.454	438.8994
				9.830189	438.8994	96.63261
124.3	29	-5.75189	-15.1698	-5.75189	33.0842	87.25504
				-15.1698	87.25504	230.1232
132.2	56	2.148113	11.83019	2.148113	4.61439	25.41258
				11.83019	25.41258	139.9534
112.4	22	-17.6519	-22.1698	-17.6519	311.5891	391.339
				-22.1698	391.339	491.5005
112.4	48	-17.6519	3.830189	-17.6519	311.5891	-67.6101
				3.830189	-67.6101	14.67035
122.5	41	-7.55189	-3.16981	-7.55189	57.03099	23.93806
				-3.16981	23.93806	10.0477
104.7	31	-25.3519	-13.1698	-25.3519	642.7182	333.8796
				-13.1698	333.8796	173.4439
101.2	37	-28.8519	-7.16981	-28.8519	832.4314	206.8626
				-7.16981	206.8626	51.40619
120.7	27	-9.35189	-17.1698	-9.35189	87.45779	160.5701
				-17.1698	160.5701	294.8024
120.3	27	-9.75189	-17.1698	-9.75189	95.0993	167.4381
				-17.1698	167.4381	294.8024
152.2	36	22.14811	-8.16981	22.14811	490.5389	-180.946
				-8.16981	-180.946	66.74582
124.1	42	-5.95189	-2.16981	-5.95189	35.42496	12.91447
				-2.16981	12.91447	4.708081
117.2	32	-12.8519	-12.1698	-12.8519	165.171	156.405
				-12.1698	156.405	148.1043
112.3	36	-17.7519	-8.16981	-17.7519	315.1295	145.0296
				-8.16981	145.0296	66.74582
120.5	27	-9.55189	-17.1698	-9.55189	91.23854	164.0041
				-17.1698	164.0041	294.8024
120.5	27	-9.55189	-17.1698	-9.55189	91.23854	164.0041
				-17.1698	164.0041	294.8024
106.7	33	-23.3519	-11.1698	-23.3519	545.3106	260.8362
				-11.1698	260.8362	124.7647
115.8	31	-14.2519	-13.1698	-14.2519	203.1163	187.6947
				-13.1698	187.6947	173.4439
96.4	40	-33.6519	-4.16981	-33.6519	1132.449	140.322
				-4.16981	140.322	17.38733
151.8	53	21.74811	8.830189	21.74811	472.9804	192.0399
				8.830189	192.0399	77.97223
123.9	42	-6.15189	-2.16981	-6.15189	37.84571	13.34843
				-2.16981	13.34843	4.708081
102.4	30	-27.6519	-14.1698	-27.6519	764.6268	391.822
				-14.1698	391.822	200.7836

CTC	V	X-Mt		X-M	X-M*X-Mt	
99.6	36	-30.4519	-8.16981	-30.4519	927.3174	248.7862
				-8.16981	248.7862	66.74582
118.9	46	-11.1519	1.830189	-11.1519	124.3646	-20.4101
				1.830189	-20.4101	3.349591
177.3	50	47.24811	5.830189	47.24811	2232.384	275.4654
				5.830189	275.4654	33.9911
124.2	36	-5.85189	-8.16981	-5.85189	34.24458	47.80881
				-8.16981	47.80881	66.74582
129.2	55	-0.85189	10.83019	-0.85189	0.725711	-9.22609
				10.83019	-9.22609	117.293
103.5	44	-26.5519	-0.16981	-26.5519	705.0027	4.508811
				-0.16981	4.508811	0.028836
106.5	51	-23.5519	6.830189	-23.5519	554.6914	-160.864
				6.830189	-160.864	46.65148
96.8	51	-33.2519	6.830189	-33.2519	1105.688	-227.117
				6.830189	-227.117	46.65148
102.6	49	-27.4519	4.830189	-27.4519	753.6061	-132.598
				4.830189	-132.598	23.33072
125.3	54	-4.75189	9.830189	-4.75189	22.58043	-46.7119
				9.830189	-46.7119	96.63261
98.6	47	-31.4519	2.830189	-31.4519	989.2212	-89.0148
				2.830189	-89.0148	8.009968
94.3	50	-35.7519	5.830189	-35.7519	1278.197	-208.44
				5.830189	-208.44	33.9911
88.4	41	-41.6519	-3.16981	-41.6519	1734.88	132.0286
				-3.16981	132.0286	10.0477
98.3	47	-31.7519	2.830189	-31.7519	1008.182	-89.8638
				2.830189	-89.8638	8.009968
106	32	-24.0519	-12.1698	-24.0519	578.4933	292.7069
				-12.1698	292.7069	148.1043
105.5	39	-24.5519	-5.16981	-24.5519	602.7951	126.9286
				-5.16981	126.9286	26.72695
89.1	42	-40.9519	-2.16981	-40.9519	1677.057	88.85787
				-2.16981	88.85787	4.708081
98.1	35	-31.9519	-9.16981	-31.9519	1020.923	292.9928
				-9.16981	292.9928	84.08544
79.9	35	-50.1519	-9.16981	-50.1519	2515.212	459.8833
				-9.16981	459.8833	84.08544
100.7	29	-29.3519	-15.1698	-29.3519	861.5333	445.2626
				-15.1698	445.2626	230.1232
112.6	36	-17.4519	-8.16981	-17.4519	304.5684	142.5786
				-8.16981	142.5786	66.74582
97.9	35	-32.1519	-9.16981	-32.1519	1033.744	294.8267
				-9.16981	294.8267	84.08544
111.9	36	-18.1519	-8.16981	-18.1519	329.491	148.2975
				-8.16981	148.2975	66.74582
99.1	27	-30.9519	-17.1698	-30.9519	958.0193	531.4381
				-17.1698	531.4381	294.8024
162.1	46	32.04811	1.830189	32.04811	1027.082	58.65409
				1.830189	58.65409	3.349591
174.8	59	44.74811	14.83019	44.74811	2002.394	663.623
				14.83019	663.623	219.9345
195.6	38	65.54811	-6.16981	65.54811	4296.555	-404.419
				-6.16981	-404.419	38.06657

MATRIZ DE COVARIANCIA				
746.9643832	153.625151	-43.14	153.63	
153.6251513	121.367391	153.63	-668.74	
AUTO VALORES (Calculado no SPSS)				
790.1072993	0			
0	86.4943009			
		110.48	-515.11	
790.1072993	0		4.662421578	
0	790.107299			
			21.73817497	
			22.73817497	
				0.209711477
				0.977763313

MEDIA CTC	130.0518868
-----------	-------------

MEDIA V	44.16981132
---------	-------------

MATRIZ TRANSPOSTA	
0.9777633	-0.2255754
0.2097115	0.9742257

MATRIZ G	
0.9777633	0.2097115
-0.2255754	0.9742257

MATRIZ INVERSA	
0.974354421	-0.20973918
0.225605171	0.977892482

MATRIZ DE COVARIANCIA				
746.9643832	153.625151	660.47	153.63	
153.6251513	121.367391	153.63	34.87	
AUTO VALORES (Calculado no SPSS)				
790.1072993	0			
0	86.4943009			
		814.10	188.50	
86.49430087	0		-0.23154323	
0	86.4943009			
			0.053612268	
			1.053612268	
				0.974226
				-0.225575

VALORES ORIGINAIS		VALORES TRANSFORMADOS		VALORES ORIGINAIS		VALORES TRANSFORMADOS		CORREL PC1	-0.00341 PC2
CTC	178.5	PC1	187.9522859	CTC	117.3	PC1	121.4024039	187.9523	22.08524
V	64	PC2	22.0852423	V	32	PC2	4.715231996	158.4225	21.73968
CTC	149.8	PC1	158.4224985	CTC	118.8	PC1	124.3370292	159.6524	25.54635
V	57	PC2	21.73967542	V	39	PC2	11.19644897	155.9781	22.30361
CTC	150.2	PC1	159.6524497	CTC	123.1	PC1	124.5568934	148.363	10.76656
V	61	PC2	25.54634815	V	20	PC2	-8.283813787	155.475	21.39706
CTC	147.3	PC1	155.9780902	CTC	124.1	PC1	134.3425387	182.5719	9.010021
V	57	PC2	22.30361385	V	62	PC2	32.40809105	165.5885	22.13166
CTC	142.3	PC1	148.3630244	CTC	174.7	PC1	182.1396705	193.3853	17.764
V	44	PC2	10.76655635	V	54	PC2	13.20017152	189.5693	4.327856
CTC	147	PC1	155.4750497	CTC	124.3	PC1	127.6176126	197.5883	9.636081
V	56	PC2	21.39706074	V	29	PC2	0.213527241	171.3958	2.384955
CTC	176	PC1	182.5719169	CTC	132.2	PC1	141.0041527	198.7886	4.246129
V	50	PC2	9.010020663	V	56	PC2	24.73557623	144.1303	9.697849
CTC	156.7	PC1	165.5884883	CTC	112.4	PC1	114.5142489	141.8545	15.33593
V	59	PC2	22.1316568	V	22	PC2	-3.921705879	168.9837	26.4614
CTC	184.7	PC1	193.385284	CTC	112.4	PC1	119.9667473	194.4015	-0.87738
V	61	PC2	17.76399785	V	48	PC2	21.40816282	141.8019	32.7324
CTC	183.8	PC1	189.5693364	CTC	122.5	PC1	128.3741764	137.7196	14.24467
V	47	PC2	4.327855612	V	41	PC2	12.31027154	132.1052	19.63037
CTC	190.5	PC1	197.5883309	CTC	104.7	PC1	108.8728747	134.3992	36.48545
V	54	PC2	9.636080661	V	31	PC2	6.583255951	159.6524	25.54635
CTC	166.5	PC1	171.3957622	CTC	101.2	PC1	106.7089719	135.7769	8.557217
V	41	PC2	2.384955215	V	37	PC2	13.21812407	164.051	17.37332
CTC	192.8	PC1	198.7886291	CTC	120.7	PC1	123.6782418	177.6278	13.21848
V	49	PC2	4.246128711	V	27	PC2	-0.922852862	162.5534	1.357111
CTC	138.4	PC1	144.1303246	CTC	120.3	PC1	123.2871364	155.0994	29.66457
V	42	PC2	9.69784886	V	27	PC2	-0.832622713	128.6675	12.2426
CTC	135	PC1	141.8544867	CTC	152.2	PC1	156.3651894	132.118	13.49177
V	47	PC2	15.33593372	V	36	PC2	0.739554424	129.8678	6.852647
CTC	159.1	PC1	168.9836776	CTC	124.1	PC1	130.1483092	188.8323	21.88222
V	64	PC2	26.4614045	V	42	PC2	12.92357667	119.6026	16.37913
CTC	189.6	PC1	194.4015177	CTC	117.2	PC1	121.3046276	154.4561	25.72256
V	43	PC2	-0.877384417	V	32	PC2	4.737789533	154.622	16.48082
CTC	131.3	PC1	141.8018575	CTC	112.3	PC1	117.3524332	157.1784	16.91366
V	64	PC2	32.73239982	V	36	PC2	9.740011728	140.7108	24.80325
CTC	131.2	PC1	137.7195631	CTC	120.5	PC1	123.4826891	141.5342	20.52287
V	45	PC2	14.24466869	V	27	PC2	-0.877737788	128.2366	23.59069
CTC	124.6	PC1	132.1051712	CTC	120.5	PC1	123.4826891	128.9918	28.52949
V	49	PC2	19.63036901	V	27	PC2	-0.877737788	200.0894	13.14951
CTC	123.3	PC1	134.399174	CTC	106.7	PC1	111.2478242	95.14305	13.84123
V	66	PC2	36.48545422	V	33	PC2	8.080556648	114.0988	15.60367
CTC	150.2	PC1	159.6524497	CTC	115.8	PC1	119.7260474	130.1355	19.06218
V	61	PC2	25.54634815	V	31	PC2	4.079369333	138.6265	8.922389
CTC	130.5	PC1	135.77686	CTC	96.4	PC1	102.6448425	124.5326	11.15133
V	39	PC2	8.557217133	V	40	PC2	17.223563	137.2307	14.35746
CTC	156.2	PC1	164.0510493	CTC	151.8	PC1	159.5391792	121.6957	4.647559
V	54	PC2	17.37331589	V	53	PC2	17.3916218	113.4117	1.445689
CTC	170.3	PC1	177.6278005	CTC	123.9	PC1	129.9527565	117.9519	3.466064
V	53	PC2	13.21847744	V	42	PC2	12.96869174	137.9421	9.080292
CTC	158.1	PC1	162.5534159	CTC	102.4	PC1	106.4143076	118.0369	9.582109
V	38	PC2	1.357111174	V	30	PC2	6.127853585	125.0228	18.19649
CTC	144.9	PC1	155.0994386	CTC	99.6	PC1	104.9348391	116.4711	2.785086
V	64	PC2	29.66457477	V	36	PC2	12.60481894	121.4024	4.715232

VALORES ORIGINAIS		VALORES TRANSFORMADOS		VALORES ORIGINAIS		VALORES TRANSFORMADOS		CORREL	-0.1894
								PC1	PC2
CTC	122.8	PC1	128.6675054	CTC	118.9	PC1	125.9027859	124.337	11.19645
V	41	PC2	12.24259893	V	46	PC2	17.99347147	124.5569	-8.28381
CTC	125.9	PC1	132.1179946	CTC	177.3	PC1	183.8430093	134.3425	32.40809
V	43	PC2	13.49176672	V	50	PC2	8.716772681	182.1397	13.20017
CTC	125.1	PC1	129.8678036	CTC	124.2	PC1	128.9878167	127.6176	0.213527
V	36	PC2	6.852646979	V	36	PC2	7.055664813	141.0042	24.73558
CTC	179.4	PC1	188.8322729	CTC	129.2	PC1	137.8611513	114.5142	-3.92171
V	64	PC2	21.88222447	V	55	PC2	24.43807662	119.9667	21.40816
CTC	113.1	PC1	119.6026242	CTC	103.5	PC1	110.4258079	128.3742	12.31027
V	43	PC2	16.37913147	V	44	PC2	19.51888075	108.8729	6.583256
CTC	145.1	PC1	154.4561453	CTC	106.5	PC1	114.8270782	106.709	13.21812
V	60	PC2	25.72255682	V	51	PC2	25.66173467	123.6782	-0.92285
CTC	147.2	PC1	154.622045	CTC	96.8	PC1	105.342774	123.2871	-0.83262
V	51	PC2	16.48081707	V	51	PC2	27.84981577	156.3652	0.739554
CTC	149.6	PC1	157.1783884	CTC	102.6	PC1	110.5943783	130.1483	12.92358
V	52	PC2	16.9136619	V	49	PC2	24.59302718	121.3046	4.73779
CTC	131.9	PC1	140.7108237	CTC	125.3	PC1	133.8381629	117.3524	9.740012
V	56	PC2	24.80324884	V	54	PC2	24.34359485	123.4827	-0.87774
CTC	133.6	PC1	141.5341754	CTC	98.6	PC1	106.2639021	123.4827	-0.87774
V	52	PC2	20.52286783	V	47	PC2	23.54687722	111.2478	8.080557
CTC	120	PC1	128.2365944	CTC	94.3	PC1	102.6886543	119.726	4.079369
V	52	PC2	23.59069288	V	50	PC2	27.43952847	102.6448	17.22356
CTC	119.7	PC1	128.9918227	CTC	88.4	PC1	95.03244742	159.5392	17.39162
V	57	PC2	28.52949409	V	41	PC2	20.00239169	129.9528	12.96869
CTC	192.2	PC1	200.0893744	CTC	98.3	PC1	105.9705731	106.4143	6.127854
V	58	PC2	13.14950541	V	47	PC2	23.61454983	104.9348	12.60482
CTC	89.8	PC1	95.1430472	CTC	106	PC1	110.3536784	125.9028	17.99347
V	35	PC2	13.84123186	V	32	PC2	7.264233688	183.843	8.716773
CTC	107.9	PC1	114.098832	CTC	105.5	PC1	111.3327771	128.9878	7.055665
V	41	PC2	15.60367196	V	39	PC2	14.19660141	137.8612	24.43808
CTC	122.8	PC1	130.1354857	CTC	89.1	PC1	95.92659322	110.4258	19.51888
V	48	PC2	19.06217896	V	42	PC2	20.81871465	114.8271	25.66173
CTC	133.2	PC1	138.6265324	CTC	98.1	PC1	103.2584827	105.3428	27.84982
V	40	PC2	8.92238935	V	35	PC2	11.96895628	110.5944	24.59303
CTC	119	PC1	124.5325819	CTC	79.9	PC1	85.4631904	133.8382	24.34359
V	39	PC2	11.1513339	V	35	PC2	16.07442803	106.2639	23.54688
CTC	130.7	PC1	137.2306815	CTC	100.7	PC1	104.5423985	102.6887	27.43953
V	45	PC2	14.35745637	V	29	PC2	5.537105997	95.03245	20.00239
CTC	117.6	PC1	121.6957329	CTC	112.6	PC1	117.6457622	105.9706	23.61455
V	32	PC2	4.647559384	V	36	PC2	9.672339116	110.3537	7.264234
CTC	110.2	PC1	113.411727	CTC	97.9	PC1	103.06293	111.3328	14.1966
V	27	PC2	1.445688534	V	35	PC2	12.01407135	95.92659	20.81871
CTC	114.2	PC1	117.9519147	CTC	111.9	PC1	116.9613279	103.2585	11.96896
V	30	PC2	3.466064207	V	36	PC2	9.830241876	85.46319	16.07443
CTC	132.5	PC1	137.9420981	CTC	99.1	PC1	102.5585542	104.5424	5.537106
V	40	PC2	9.08029211	V	27	PC2	3.949575152	117.6458	9.672339
CTC	113	PC1	118.0368675	CTC	162.1	PC1	168.142161	103.0629	12.01407
V	36	PC2	9.582108968	V	46	PC2	8.248615444	116.9613	9.830242
CTC	118	PC1	125.0227989	CTC	174.8	PC1	183.2860043	102.5586	3.949575
V	46	PC2	18.19648931	V	59	PC2	18.04874258	168.1422	8.248615
CTC	112.9	PC1	116.4711109	CTC	195.6	PC1	199.2195402	183.286	18.04874
V	29	PC2	2.78508647	V	38	PC2	-7.101965239	199.2195	-7.10197

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programa de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. São aceitos tanto programas fonte quanto executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.