

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
Escola de Engenharia
Programa de Pós-Graduação em Engenharia de Minas,
Metalúrgica e Materiais (PPGEM)

**SIMULAÇÃO DE LITOTIPOS DE DEPÓSITO DE MINÉRIO DE FERRO
COM GEOESTATÍSTICA DE MÚLTIPLOS PONTOS**

Antônio Alves da Silva Júnior

Dissertação para obtenção do título de
Mestre em Engenharia

Porto Alegre, RS

2013

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
Escola de Engenharia
Programa de Pós-Graduação em Engenharia de Minas,
Metalúrgica e Materiais (PPGEM)

**SIMULAÇÃO DE LITOTIPOS DE DEPÓSITO DE MINÉRIO DE FERRO
COM GEOESTATÍSTICA DE MÚLTIPLOS PONTOS**

Antônio Alves da Silva Júnior

Engenheiro de minas

Trabalho realizado no Laboratório de Pesquisa Mineral e Planejamento Mineiro (LPM) da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, dentro do Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e Matérias (PPGEM), como parte dos requisitos para obtenção do título de Mestre em Engenharia.

Área de concentração: Tecnologia Mineral, Ambiental e Metalurgia Extrativa.

Porto Alegre, RS

2013

Esta dissertação foi julgada adequada para obtenção do título de Mestre em Engenharia, área de concentração Tecnologia Mineral, Ambiental e Metalurgia Extrativa, e aprovada em sua forma final pelo Orientador e pela Banca Examinadora do Curso de Pós-Graduação.

Orientador:

Prof. Dr. João Felipe Coimbra Leite Costa

Banca Examinadora:

Profa. Dra. Daiane Folle

Profa. Dra. Vanessa Cerqueira Koppe

Prof. Dr. Rodrigo de Lemos Peroni

Prof. Dr. Telmo Roberto Strohaecker

Coordenador do PPGEM

To dream the impossible dream,
To fight the unbeatable foe,
To bear with unbearable sorrow,
To run where the brave dare not go,
To right the unrightable wrong,
To love, pure and chaste, from afar,
To try, when your arms are too weary,
To reach the unreachable star!

Man of La Mancha
(Wasserman et al., 1966)

Agradecimentos

A realização deste trabalho não seria possível sem a ajuda de muitas pessoas que me apoiaram ao longo desta jornada. Primeiro e mais importante, eu desejo expressar meus sinceros agradecimentos ao meu orientador, Prof. João Felipe. Durante estes anos, ele foi um professor excepcional e um grande amigo. Sua paciência, entusiasmo, habilidade técnica e dedicação, não só me ajudaram como permitiram também meu crescimento profissional e pessoal.

Ao Prof. Dr. Rodrigo Peroni e Prof. Jair Koppe pela amizade e ensinamentos em planejamento de lavra. A Profa. Dra. Vanessa Koppe pelos incontáveis auxílios nas atividades de geoestatística, sempre disposta e atenciosa.

Aos colegas do LPM, Paulo Dias, Taís Câmara, Henrique Shibata, Camila Zacché, Diego Marques, Luís Gustavo, Sarah Guazzelli, Carla de Carli, Marcel Bassani, George Gasper e Anuar Pires.

Aos colegas da Vale pelos incentivos, Lilian Masetti, Leonardo Faria, Cristina Magni e Letícia Rodrigues.

Ao amigo Marivaldo Nascimento e familiares que mesmo distantes torcem e rezam pelo meu sucesso.

E por último, mas não menos importante a Deus, que colocou essas pessoas sensacionais no meu caminho e tornou tudo isso possível.

Índice

Lista de Figuras	ix
Lista de Tabelas	xiv
Resumo	xv
Abstract	xvi
Capítulo 1 – Introdução.....	1
1.1. Modelagem geológica e a geoestatística.....	1
1.2. Objetivos.....	7
1.3. Organização da dissertação.....	8
Capítulo 2 – Simulação geoestatística e variáveis categóricas.....	9
2.1. Abordagem probabilística.....	10
2.2. Simulação geoestatística.....	11
2.2.1. Breve histórico inicial.....	11
2.2.2. Simulação sequencial condicional.....	13
2.3. Simulação de variáveis categóricas.....	15
2.3.1. Simulação sequencial dos indicadores.....	15
2.3.2. Simulação de múltiplos pontos.....	19
Capítulo 3 – Testes e comparações.....	24
3.1. Análise de sensibilidade dos parâmetros do <i>SNESIM</i>	26
3.1.1. Reproduzindo padrões.....	26
3.1.2. Reproduzindo proporções	32

3.2. <i>SISIM</i> vs. <i>SNESIM</i>	33
3.3. Discussões.....	34
Capítulo 4 – Simulação de litotipos de depósitos de minério de ferro com <i>SNESIM</i>: desafios e soluções.....	36
4.1. Integração de informações geológicas.....	36
4.2. Metodologia proposta.....	43
4.2.1. <i>Exemplo esquemático</i>	47
Capítulo 5 – Aplicação da metodologia: estudo de caso em 3D.....	52
5.1. Aspectos geológicos.....	52
5.2. Dados disponíveis.....	56
5.3. Aplicação da metodologia proposta.....	60
5.3.1. Modelo geológico.....	60
5.3.2. Imagem de treinamento.....	62
5.3.3. Modelos de probabilidades.....	62
5.3.4. Simulação dos litotipos.....	64
5.3.5. Comparações e validações.....	65
5.4. Quantificação da incerteza.....	69
5.5. Discussões.....	71
Capítulo 6 - Conclusões e recomendações.....	73
6.1. Objetivos <i>versus</i> resultados.....	73
6.2. Trabalhos futuros.....	75
Capítulo 7 – Referências bibliográficas.....	76
ANEXOS.....	84

Lista de Figuras

- Figura 1.1: mina de urânio Mary Kathleen, Austrália, modelo geológico do minério interpretado durante o estudo de viabilidade (esquerda) e quando lavrado (direita).....3
- Figura 1.2: mina de cobre/chumbo/zinco CSA, Austrália, modelo geológico baseado nos furos de exploração (esquerda) e de curto prazo (direita).....3
- Figura 1.3: perfil esquemático do depósito de cobre Sequeirinho, Brasil, mostrando as distribuições das zonas de alteração hidrotermal.....4
- Figura 1.4: enriquecimento supergênico de um depósito de cobre, México.....4
- Figura 1.5: limitação do variograma na diferenciação de geometrias complexas extremamente diferentes.....6
- Figura 2.1: (A) estratificação cruzada acanaladas com alternância de camadas laminares (claras) e arenosas (escuras); (B) resultado da simulação os indicadores; (a) e (b) interpretação das principais laminações das camadas escuras correspondentes a (A) e (B).....18
- Figura 2.2: varredura da imagem de treinamento, (A) t_i ; (B) tamanho de molde; (C) frequência dos possíveis moldes; (D) árvore de busca; e (E) frequência (histograma de múltiplos pontos) das prováveis configurações (Branco = B; Azul escuro = A; Azul claro = desconhecido).....22
- Figura 3.1: frequência relativa dos indicadores com o respectivo sumário estatístico; e mapa de localização do estéril (azul) e minério (vermelho).....26
- Figura 3.2: imagens de treinamento com os respectivos histogramas. (t_i 1= imagem de treinamento um; t_i 2= imagem de treinamento dois; t_i 3= imagem de treinamento três); e variogramas de maior (acima) e menor (abaixo) continuidade espacial.....27

- Figura 3.3: resultados das simulações com imagem de treinamento e tamanhos e/ou direções de moldes diferentes. (*az*= azimute; *dip*= mergulho; *rake*= obliquidade; *max*= alcance máximo; e *min*= alcance mínimo).....28
- Figura 3.4: limitação do molde em reproduzir estruturas longas (em preto) satisfatoriamente; (A) imagem de treinamento; (B) simulação realizada a partir de um único molde de varredura com tamanho de 9x9; e (C) um único molde de varredura com tamanho de 35x35.....29
- Figura 3.5: múltiplos de moldes de busca; (A) reprodução dos padrões capturados pelo molde maior (D); (B) reprodução dos padrões capturados pelo molde menor (E); e (C) resultado da simulação ao acessar (A) e (B).....30.
- Figura 3.6: resultados das simulações com imagem de treinamento e número de malhas diferentes. (*mg*= múltiplos moldes).....31
- Figura 3.7: resultados das simulações com diferentes imagens de treinamento.....35
- Figura 3.8: comparação entre os resultados das simulações geradas pelo algoritmo *SISIM* e *SNESIM*, e os dados exaustivos do banco de dados *Walker Lake*.....35
- Figura 4.1: distribuição das amostras do banco de dados Walker Lake modificado, os retângulos identificam as amostras retiradas do banco é, posteriormente, usadas na etapa de validação (esquerda); e resultado de uma simulação por *SNESIM* e a imagem de treinamento utilizada (direita). (vermelho / amarelo = minério; azul / verde = estéril).....37
- Figura 4.2: distribuição dos furos de sondagem originais (esquerda) e integrados aos furos “fantasmas” (direita).....38
- Figura 4.3: seções verticais e furos de sondagens utilizados como dados originais na simulação; em verde, minério e azul, estéril. Note as áreas vazadas entre os litotipos deixadas propositalmente sem definição da geologia.....39

- Figura 4.4: imagem de treinamento não estacionaria (esquerda) e resultado da simulação por meio do algoritmo *SNESIM* (direita).....40
- Figura 4.5: exemplo esquemático da utilização de uma técnica de controle de modelos não estacionários. (A) imagem de treinamento; (B) localização dos dados originais; (C) e (D) mapas indicando as regiões com padrões de rotação e espessura diferentes; (E) informações secundárias de sísmica; e (F) resultado da simulação.....41
- Figura 4.6: simulação com a concepção de regiões: cada região está associada a uma imagem de treinamento específica (preto = fácies de folhelho; cinza escura = canais; cinza = crevasse; cinza clara = diques).....42
- Figura 4.7: resumo esquemático da metodologia proposta representado em forma de um diagrama. No eixo X, as etapas do método, no eixo Y, o nível de quantificação da incerteza sobre o modelo.....47
- Figura 4.8: modelo geológico interpretado do banco de dados Walker Lake modificado (esquerda) e três imagens de treinamento (direita), respectivamente em sentido horário: ti1, ti2 e ti3. (vermelho = minério e azul = estéril).....48
- Figuras 4.9: mapa de probabilidade do minério (esquerda) e estéril (direita) construído por algoritmo de janelas móveis, em destaque as escalas com as respectivas probabilidades representadas por diferentes cores.....49
- Figura 4.10: duas realizações com *SNESIM* utilizando informações geológicas baseadas na interpretação como dados secundários.....50
- Figura 4.11: modelo de incerteza geológica da categoria estéril (esquerda) e minério (direita) com a respectiva escala de probabilidade.....51
- Figura 5.1: mapa de localização e geológico da região do Quadrilátero Ferrífero.....53
- Figura 5.2: coluna estratigráfica do Quadrilátero Ferrífero.....54

- Figura 5.3: seção vertical esquemática do depósito de ferro estudado com direções Leste-Oeste, em destaque, as principais características estruturais e litoestratigráficas.....55
- Figura 5.4: principais tipologias do depósito de minério de ferro da Formação Cauê do Grupo Itabira, quartzo itabirito (A) e hematitito friável (B).....56.
- Figura 5.5: mapa de localização dos furos de sondagem utilizados nas simulações (*hard data*) em seção paralela ao plano horizontal.....58
- Figura 5.6: seção transversal interpretada da geológica do depósito, parte superior, e simplificada, na parte inferior.....59
- Figura 5.7: sólido geológico (*wireframe*) da tipologia hematitito (A) e itabirito (B).....61
- Figura 5.8: extrusão da imagem de treinamento a partir das seções interpretadas (A) e imagem de treinamento utilizada na simulação (B).....62
- Figura 5.9: seções transversais dos modelos de probabilidade das categorias hematitito (A), itabirito (B) e estéril (C).....63
- Figura 5.10: resultado da realização 25, onde são mostrados a vista geral do depósito simulado (A) e o depósito seccionado (B) nos planos horizontal (I), de perfil NS (II) e frontal LO (III).....65
- Figura 5.11: : comparação entre o modelo de referência (A) e o modelo simulado (B), em destaque as seções nos planos horizontais (I), de perfil na direção NS (II) e lateral na direção LO (III) dos modelos.....66
- Figura 5.12: proporções dos litotipos por realização em comparação as proporções do modelo de referência.....67
- Figura 5.13: seções transversais das simulações 59 (A) e 87 (B) em confronto com os furos de sondagem utilizados como amostras primárias.....68

Figura 5.14: seções transversais das simulações 83 (A) e 12 (B) em confronto com os furos de sondagem removidos do banco de dados.....	68
Figura 5.15: distribuição das probabilidades das tipologias de acordo com a incerteza.....	69
Figura 5.16: modelo de classificação construído a partir dos modelos de probabilidade.....	70
Figura 5.17: comparação entre os volumes do modelo de classificação com 100% de probabilidade e os volumes do modelo de referência.....	71

Lista de Tabelas

- Tabela 3.1: proporções de minério e estéril das simulações com imagens de treinamento, distribuições marginais e fatores de ajuste diferentes. (*sf*=fator; *est%*= estéril; *min%*= minério; *target hd*= proporções marginais correspondente as amostras primárias).....33
- Tabela 3.2: proporções de minério e estéril das simulações com imagens de treinamento, distribuições marginais e fatores de ajuste diferentes. (*sf*=fator; *est%*= estéril; *min%*= minério; *target ti*= proporções marginais correspondentes as imagens de treinamento).....33

Resumo

A distribuição espacial e o volume dos domínios litológicos são frequentemente as maiores fontes de incerteza na modelagem geológica. Geralmente, a interpretação destas características é baseada em critérios subjetivos de observações, sem levar em consideração a incerteza inerente a este processo. Existem métodos de simulação geoestatísticos capazes de quantificar esta incerteza tipológica das unidades geológicas. A maioria desses métodos utiliza como medida de continuidade geológica os modelos de covariância. Entretanto, estas ferramentas de estatística de dois-pontos, raramente, conseguem capturar os padrões de geometrias complexas. Uma alternativa para esta limitação é utilizar métodos de estatística de múltiplos pontos para reproduzir os padrões espaciais de heterogeneidade que são informados por uma imagem de treinamento. Nessa dissertação, será aplicada a geoestatística de múltiplos pontos (*SNESIM*) para simular os litotipos de um depósito de minério de ferro. A imagem de treinamento foi baseada em seções interpretadas. Os furos de sondagem são utilizados como amostras primárias. As informações geológicas são acessadas por mapas de probabilidade utilizados como informações secundárias. A metodologia é testada na simulação de um depósito de ferro brasileiro com três diferentes litotipos. Os resultados das simulações são comparados contra um modelo de referência e novos furos de sondagens. As geometrias e distribuição espacial das tipologias foram reproduzidas de forma consistente. A incerteza das distribuições e dos volumes dos domínios tipológicos foi quantificada. O algoritmo de múltiplos pontos e a metodologia proposta mostraram grande potencial de aplicação na simulação de depósitos minerais.

Palavras-chaves: modelagem geológica, modelagem da incerteza, estatística de múltiplos pontos, algoritmo snesim, depósitos minerais.

Abstract

The spatial distribution and volumes of lithological domains are often the biggest sources of uncertainty in geological modeling. Usually, the interpretation of these characteristics is based on subjective criteria of observations, without taking into account the uncertainty inherent in this process. There geostatistical simulation methods capable of quantifying this uncertainty typological geological units. Most of these methods uses as a measure of continuity in geological models covariance. However, these two-point statistical is rarely sufficient to capture the patterns of complex geometries. An alternative to this limitation is to use statistical methods of multiple points to reproduce the spatial patterns of heterogeneity that are informed by a training image. In this dissertation, will be applied to multi-point geostatistics (SNESIM) to simulate lithotypes a deposit of iron ore. The training image was based on sections interpreted. The drillholes are used as primary samples. Geologic information is accessed by probability maps used as secondary information. The methodology is tested in the simulation of a deposit of Brazilian iron with three different rock types. The simulation results are compared against a reference model and new drillholes. The geometries and spatial typologies were reproduced consistently. The uncertainty distributions and volumes of typological domains were quantified. The algorithm of multiple points and the proposed methodology showed great potential for application in the simulation of mineral deposits.

Keywords: geologic modeling, uncertainty modeling, multiple-point statistics, snesim algorithm, mineral deposits

Capítulo 1

Introdução

1.1. Modelagem geológica e a geoestatística

O modelo geológico de um depósito mineral é a base de referência para as decisões técnicas e econômicas de um projeto de mineração. A avaliação e classificação de recursos minerais e reservas de minério, a engenharia de mina, o planejamento e controle dos processos de lavra e beneficiamento são baseados nele. No entanto, apesar de ser um aspecto crucial, a incerteza associada a esse modelo é muitas vezes negligenciada.

Várias fontes de incerteza estão presentes na modelagem geológica. Algumas delas são mostradas nos próximos exemplos. Sides (1992) conduziu uma pesquisa sobre a incerteza na localização das amostras geológicas de furos de sondagem. O autor comparou a localização das amostras interpretadas com as observadas durante as escavações da mina subterrânea de cobre Neves-Corvo (Portugal). Os resultados indicaram um erro médio aproximado de 2 m na direção vertical e 3 m na direção horizontal para furos entre 400 m a 500 m de profundidade.

Outra fonte de incerteza é a interpretação. King *et al.* (1986) investigaram o efeito da complexidade geológica e do número limitado de amostras sobre a modelagem geológica. Os autores realizaram dois estudos, um para cada caso. A Figura 1.1 mostra o modelo interpretado e o lavrado da mina de urânio Mary Kathleen (Austrália). As discrepâncias ilustram os problemas envolvidos quando suposições sobre a geologia (contornos do minério) são demasiadamente suaves e contínuas. Os autores concluíram que a falta de conhecimento sobre a geologia do depósito conduziu para uma subestimativa de 30 % a 40 % de toneladas de minério e uma superestimativa similar dos teores de urânio. A Figura 1.2 apresenta um modelo baseado nos

furos de exploração e outro nos furos de curto prazo da mina de cobre/chumbo/zinco CSA (Austrália). O caso ilustra como a falta de dados, quando combinada à incorreta interpretação geológica resulta em uma superestimativa dos teores. Os autores afirmam que, depois de 20 anos de operação, o teor médio de minério lavrado foi de 1.7 % Cu, comparado a uma expectativa de teor de 3.5 % Cu.

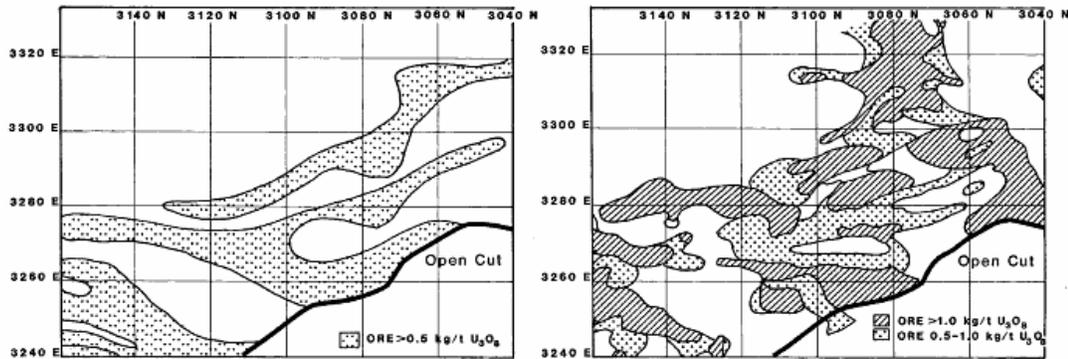


Figura 1.1: mina de urânio Mary Kathleen, Austrália, modelo geológico do minério interpretado durante o estudo de viabilidade (esquerda) e quando lavrado (direita). Fonte: King *et al.*, 1986.

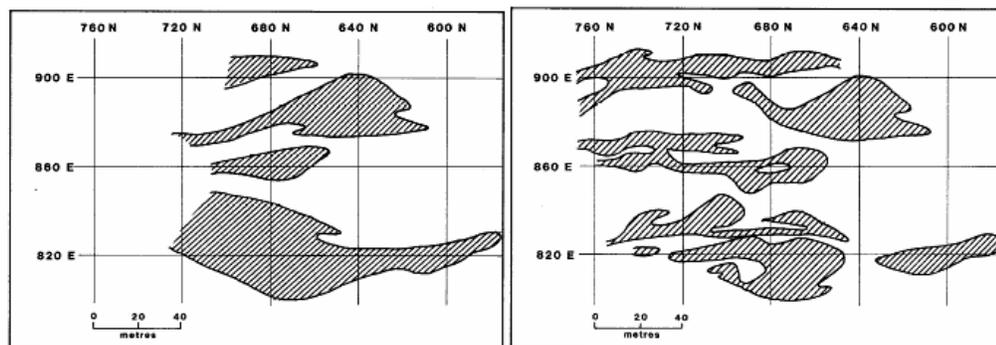


Figura 1.2: mina de cobre/chumbo/zinco CSA, Austrália, modelo geológico baseado nos furos de exploração (esquerda) e de curto prazo (direita). Fonte: King *et al.*, 1986.

Na prática, não são raras as discrepâncias entre os modelos e os depósitos. Nas décadas de 80 e 90, várias empresas de exploração e produção de ouro faliram devido a graves erros cometidos na estimativa de teores e na quantificação das massas de minério (Knoll, 1989; Clow, 1991; Champigny e Armstrong, 1994). Recentemente, algumas empresas motivadas por esse fato e por exigências reguladoras (JORC, 2004) começaram analisar o risco da incerteza da

variabilidade de teores sobre o planejamento de lavra (Thwaites, 1998; Dimitrakopoulos, 1998; Peroni, 2002; Richmond, 2004; Diedrich, 2012). Estudos sobre a incerteza da geometria, da distribuição e dos tipos de rochas continuam escassos na indústria mineral.

A arquitetura e arcabouço do depósito afetam a mineração de várias maneiras. A Figura 1.3 mostra o depósito de cobre do Sequeirinho, Brasil. A mineralização é hospedada nas rochas plutônicas básicas que intrudiram em uma seqüência de rochas vulcânicas félsicas. Essas rochas foram alteradas através de processo hidrotermal para rochas ricas em actinolita e magnetita. O grau de alteração e a mineralogia dessas rochas influenciam no índice de moabilidade (Bergerman, 2009), no processo de flotação (Rosa e Rodrigues, 2009), no desmonte de rochas (Moraes, 2004), nas tonelagens (Dias, 2012) e no seqüenciamento de lavra (Diedrich, 2012). A modelagem das incertezas dos litotipos e da distribuição das rochas alteradas pode contribuir para aperfeiçoar esses processos.

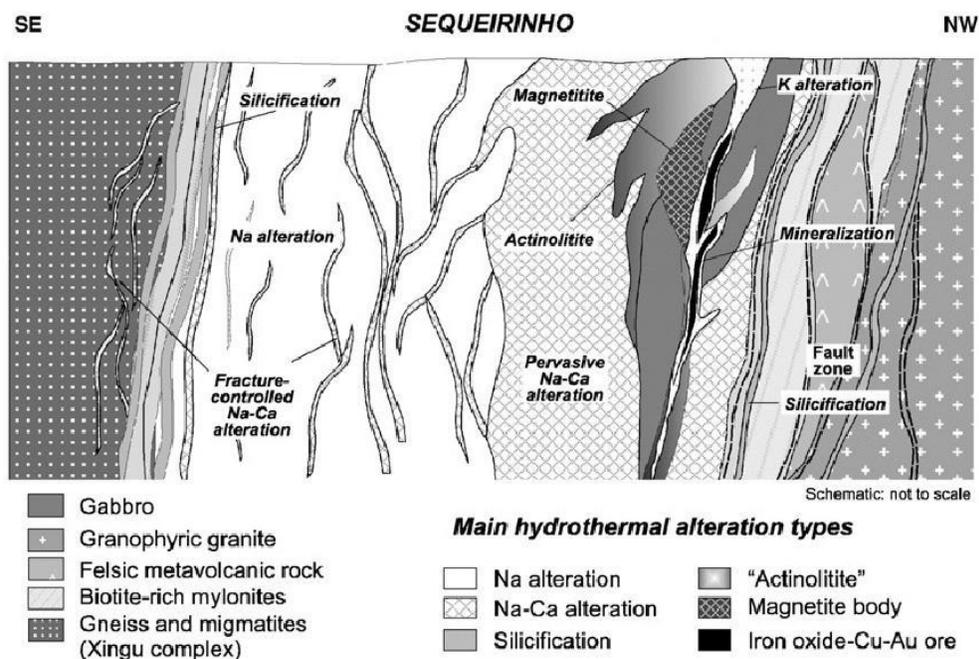


Figura 1.3: perfil esquemático do depósito de cobre Sequeirinho, Brasil, mostrando as distribuições das zonas de alteração hidrotermal. Fonte: Monteiro *et al.*, 2008.

Depósitos de cobre formados por processos de enriquecimento supergênico (Figura 1.4) podem formar corpos de minérios sulfetados e oxidados com contatos entre eles irregulares. Geralmente, esses contatos são graduais e, quando modelados como contatos abruptos baseados no teor de corte, causam problemas na classificação de recursos e cálculo de reservas. A modelagem da incerteza entre os contatos pode auxiliar na decisão da rota de processamento, uma vez que, os minérios sulfetados são tratados por flotação e os oxidados por processos hidrometalúrgicos.

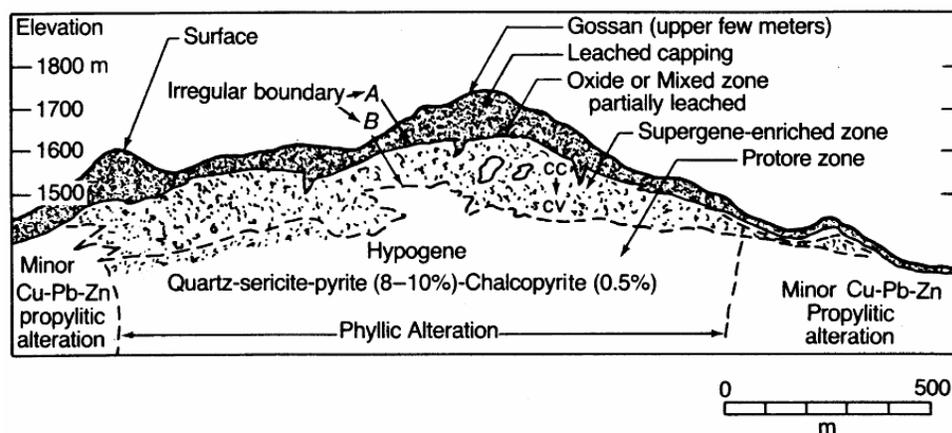


Figura 1.4: enriquecimento supergênico de um depósito de cobre, México. Fonte: Guilbert e Park (1986).

Os depósitos minerais são produtos da combinação de diferentes processos geológicos que ocorreram durante milhões ou bilhões de anos. Os processos tectônicos, por exemplo, podem resultar em fissuras, dobramentos, conjunto de fraturas ou zonas de cisalhamento; e os processos de deposição ou intrusão podem gerar planos de acamamento, fácies, lentes e veios dentro das unidades geológicas. Geralmente, depósitos de origem sedimentar apresentam uma geometria simples e uma continuidade lateral evidente, enquanto os provenientes de processos ígneos e metamórficos possuem uma geometria complexa e maior variabilidade (Noble, 1992). Esse fato não é regra. O depósito sedimentar de bauxita St. Elizabeth, Jamaica, por exemplo, apresenta baixa continuidade geológica. A explicação é que processos tectônicos pós-deposicionais produziram várias discontinuidades no depósito (Hill, 1977). Interpretações geológicas simplistas, além de ariscadas, são negligentes com a incerteza inerente à geociências.

Usualmente, as geometrias e a distribuição dos domínios geológicos são delineadas por métodos de interpolação lineares em programas de modelagem geológica. Osterholt (2006) listou algumas inconveniências desse procedimento: (i) a técnica é demasiadamente simplista; (ii) o conhecimento geológico é incluído somente de maneira subjetiva e para um limite extenso; (iii) limitações no monitoramento do processo; e (iv) inabilidade para capturar estruturas complexas em 3D. Esses métodos de modelagem das geometrias são essencialmente subjetivos e deterministas, por isso são necessários métodos probabilísticos que permitam o entendimento da incerteza desses contornos.

A interpretação de que um conjunto de amostras geológicas se comporta como uma função probabilística tem origem na geoestatística (Matheron, 1963). A geoestatística desenvolveu uma classe de métodos lineares, chamados de krigagem, capazes de oferecer estimativas ótimas e não tendenciosas, a partir de um modelo de covariância. Estimativas ótimas e não tendenciosas significam que as mesmas são obtidas de maneira a apresentar erro médio nulo e mínima variância do erro. A desvantagem desses métodos é que minimizam a variância da estimativa. Os resultados dessa limitação são distribuições da estimativa do atributo demasiadamente suavizadas. Métodos diferentes são requeridos para acessar a incerteza local de valores não amostrados e reproduzir a distribuição global de um depósito.

Os métodos de simulação condicional são os indicados para o problema apresentado. O princípio básico deles é gerar vários cenários equiprováveis da distribuição espacial da variável em estudo, reproduzindo as características randômicas da distribuição de amostras. Assim, a partir da análise do conjunto de cenários, é possível medir a incerteza local ou global associada. Entretanto, muitos desses métodos reproduzem a variabilidade espacial dos dados a partir da estatística entre dois pontos, que é capturada pelo variograma. Essa estatística baseada em dois pontos não consegue diferenciar e reproduzir geometrias curvilineares complexas, que são comuns aos processos geológicos, tais como: canais fluviais, dobras, falhas, fraturas, estruturas sedimentares e corpos magmáticos irregulares. Considere por exemplo as três imagens com padrões de distribuições espaciais extremamente diferentes da Figura 1.5. Estas imagens, de mesma proporção de células azuis (28%), que podem ser correspondentes às secções horizontais de um ambiente geológico fluvial, apresentam variogramas similares ao longo das direções Leste-

Oeste e Norte-Sul. Assim qualquer algoritmo baseado na estatística de dois pontos como medida de conectividade, não conseguirá capturar e reproduzir a diferença entre essas estruturas.

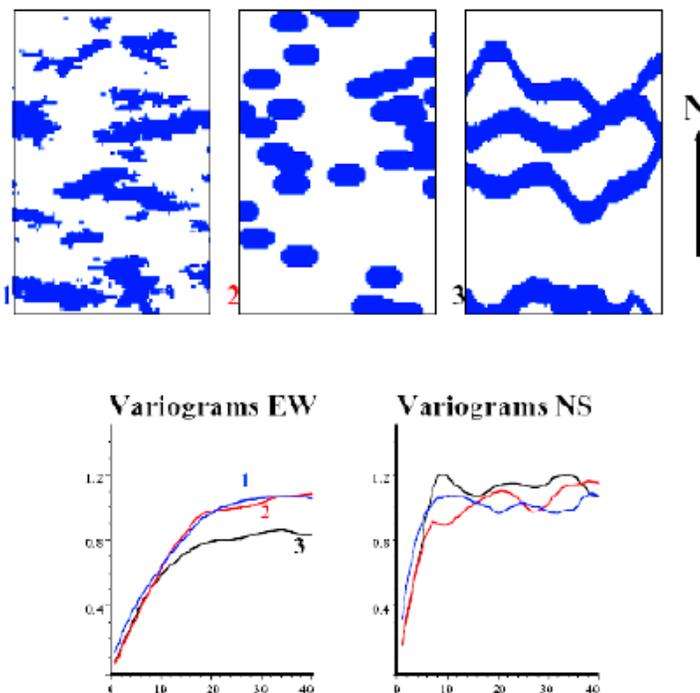


Figura 1.5: limitação do variograma na diferenciação de geometrias complexas extremamente diferentes. Fonte: Caers e Zhang (2004).

Uma alternativa para reproduzir essas geometrias complexas foi desenvolvida por Guardiano e Srivastava (1993). Os autores propuseram reproduzir a variabilidade espacial dos dados por meio da estatística de múltiplos pontos, que seria capturada por uma imagem de treinamento. A idéia resolveu o problema, embora em termos operacionais não funcionasse, pois o código original exigia uma capacidade computacional extrema para processar os dados. A solução operacional foi apresentada por Strébel (2000) que desenvolveu um novo código de simulação, o algoritmo *SNESIM* (*Single Normal Equation Simulation*). Desde então, vários algoritmos de simulação de múltiplos pontos têm sido criados em resposta a novos desafios da modelagem: *SIMPAT* (Arpat, 2004); *FILTERSIM* (Zhang e Journel, 2008); *DISPAT* (Honarkhah e Caers, 2010); e *IMPALA* (Straubhaar *et al.*, 2011).

Inicialmente, os novos métodos de simulação foram aplicados na modelagem de reservatório de petróleo. Devido a essa origem, os algoritmos desenvolvidos foram ajustados e testados em ambientes sedimentares clásticos com amostras primárias largamente espaçadas, disponíveis de poços de produção, e dados secundários exaustivos de exploração geofísica. Na modelagem de depósitos, essas condições são diferentes: o ambiente geológico é geralmente formado por rochas ígneas e/ou metamórficas e afetado por deformações e alterações complexas, as amostras primárias são relativamente densas e as informações geofísicas são incomuns. Assim, devido às diferenças entre ambas, é necessário avaliar o desempenho desses métodos com geoestatística de múltiplos pontos em depósitos minerais.

1.2. Objetivos

O objetivo geral dessa dissertação é avaliar a aplicação da geoestatística de múltiplos pontos na modelagem de depósitos minerais e quantificar a incerteza associada a esse procedimento.

Os objetivos específicos para alcançar esse objetivo são:

- i. Revisar os conceitos teóricos e práticos da simulação da incerteza;
- ii. Testar e discutir a utilização de dois algoritmos de simulação de variáveis categóricas, o *SISIM* e o *SNESIM*, em um estudo de caso ilustrativo do banco de dados *Walker Lake*;
- iii. Investigar a aplicabilidade do algoritmo *SNESIM* na simulação da incerteza de litotipos de depósitos de minério de ferro, por meio de estudos de casos;
- iv. Propor uma metodologia para o problema apresentado;
- v. Comparar os resultados gerados com aqueles interpretados por métodos tradicionais de modelagem geológica;
- vi. Avaliar a aplicação da simulação de múltiplos pontos como ferramenta de auxílio para modelagem geológica;

vii. Investigar maneiras de incorporar a incerteza de litotipos na rotina de avaliação de recursos.

1.3. Organização da dissertação

Os capítulos dessa dissertação estão organizados de acordo com os objetivos específicos requeridos para alcançar o objetivo geral proposto na seção anterior.

Capítulo 2: revisa as principais ferramentas e metodologias geoestatísticas de modelagem da incerteza de variáveis categóricas.

Capítulo 3: testa e compara os algoritmos *SISIM* e *SNESIM* por meio de um estudo de caso do banco de dados *Walker Lake*.

Capítulo 4: propõe e exemplifica uma metodologia para simulação da incerteza de litotipos de depósitos de minério de ferro.

Capítulo 5: aplica a metodologia proposta em um estudo de caso real em 3D; discute os resultados; e propõem maneiras de incorporar a incerteza de litotipos na rotina de avaliação de recursos.

Capítulo 6: apresenta as conclusões e recomendações para trabalhos futuros.

Capítulo 2

Simulação geoestatística e variáveis categóricas

“Eu sou uma mentira que sempre fala a verdade”

Jean Cocteau

Depósitos minerais provenientes de vários períodos de mineralização, muitas vezes, exibem uma mistura de tipos de rochas com características químicas e físicas diferentes. Geralmente, a avaliação desses depósitos é um desafio para geólogos e geoestatísticos. Na prática, dois procedimentos são realizados para esses casos de populações de rochas distintas: (i) as geometrias relativas a esses litotipos são modeladas ou simuladas; e (ii) a distribuição espacial de um específico atributo contínuo para cada população é estimada ou simulada. Esses procedimentos não somente honram melhor a geologia, mas produzem uma redução drástica da variabilidade estatística do depósito.

Devido às incertezas associadas a esses procedimentos de modelagem, os métodos de simulação geoestatísticas são os que melhor reproduzem as prováveis distribuições de litotipos e teores de minério de um depósito. Uma vez que, os métodos de modelagem tradicional partem de um pressuposto determinista e os de estimativa suavizam os resultados. Para os casos de simulação de geometrias ou da distribuição de litotipos, muitos algoritmos de simulação de variáveis categóricas podem ser utilizados: simulação de objetos e booleanos (Ripley, 1987; Haldorsen *et al.*, 1988; Suro-Pérez, 1991); simulação gaussiana truncada (Journel e Isaaks, 1984; Matheron *et al.*, 1987; Xu e Journel, 1993); simulação seqüencial dos indicadores (Journel, 1989; Alabert e Massonnat, 1990); simulação *annealing* (Deutsch e Journel, 1992; Farmer, 1992; Goovaerts e Journel, 1996); e simulação de múltiplos pontos (Guardiano e Srivastava, 1993; Strébel, 2002).

Neste capítulo, os métodos de simulação seqüencial dos indicadores e o de múltiplos pontos são investigados e descritos. A seção 2.1 apresenta a geoestatística através de uma ótica

probabilística. A seção 2.2 mostra a evolução dos principais conceitos da simulação geoestatística. A seção 2.3 avalia os métodos de simulação de variáveis categóricas investigados.

2.1. Abordagem probabilística

A simulação geoestatística é baseada na concepção de função randômica, que define um conjunto de valores não amostrados pertencentes a um domínio como variáveis aleatórias espacialmente dependentes (Chilès e Delfiner, 1999). Uma variável aleatória (VA) é aquela que pode assumir uma série de prováveis resultados, cada um deles tendo certa probabilidade ou frequência de ocorrer (Goovaerts, 1997). Geralmente, essa variável é representada pela letra maiúscula, Z , enquanto os prováveis resultados por uma letra minúscula correspondente, z . A variável aleatória pode ser contínua com o resultado ocorrendo dentro de um intervalo, $\{z \in [z_{min}, z_{max}]\}$, por exemplos, teores de depósitos de minério ou permeabilidade das rochas de reservatório de petróleo; ou categórica com n resultados, $\{z_k, k=1, \dots, K\}$, tais como, litofácies, litotipos ou solos.

No caso das variáveis categóricas, para cada resultado z_k é associado um valor de probabilidade, de tal modo que:

$$p_k = Prob\{Z = z_k\} \in [0,1], \quad \text{com} \quad \sum_{k=1}^K p_k = 1 \quad (2.1)$$

No caso das variáveis contínuas, a distribuição dos valores da probabilidade é representada na forma de:

- i. Função de distribuição cumulativa, representada como um histograma cumulativo, provendo a probabilidade da VA não exceder um determinado valor limite z ;

$$F(z) = Prob\{Z \leq z\} \in [0,1] \quad (2.2)$$

- ii. Função densidade de probabilidade, desenhada como um histograma, que é definida como a derivada da função anterior nos locais onde os valores z de F são diferenciáveis;

$$f(z) = dF(z)/dz \quad (2.3)$$

A função randômica (*FR*), simbolizada por $Z(u)$, é definida como um conjunto de variáveis aleatórias dependentes entre si $\{Z(u), u \in D\}$ e pertencentes ao mesmo domínio D . Assim como uma única variável aleatória Z é caracterizada por uma função de distribuição, para o caso das variáveis contínuas, uma *FR* $Z(u)$ é representada por uma função de distribuição multivariada:

$$Prob\{Z(u)\} \leq z, u \in D \quad (2.4)$$

A *FR* apresenta o comportamento duplo das variáveis regionalizadas: o aleatório, uma componente associada com a aleatoriedade local; e o estruturado, que reflete a continuidade espacial do fenômeno. Tal característica permitiu aplicar os conceitos da teoria da probabilidade das *FR* na geoestatística (Matheron, 1963). Assim como, os fundamentos da geoestatística na concepção probabilística, em especial, na simulação. Uma vez que, a simulação “clássica” não reproduz a autocorrelação espacial entre as variáveis.

2.2. Simulação geoestatística

2.2.1. Breve histórico inicial

Os primeiros métodos de simulação geoestatística surgiram durante a terceira geração de computadores (1965-1980), marcada pelo desenvolvimento dos circuitos integrados, que são capazes de armazenar dezenas de transmissores em um único chip de silício. Essa nova tecnologia de armazenamento permitiu produzir computadores com maior capacidade de processamento, os supercomputadores. Essas supermáquinas inovaram na arquitetura, pois executavam uma instrução dividindo-a em partes, como na linha de montagem de carro de um carro. Antes disso, o crescimento da eficiência dos computadores estava limitado pelo processamento escalar que exigia que o processador central de um computador terminasse uma tarefa para começar outra, produzindo o que ficou conhecido como o gargalo de Von Neumann. Apesar dos avanços tecnológicos mostrados, um supercomputador de processamento Cray-1, por exemplo, que podia executar mais de 160 milhões de instruções por segundo e suportava oito megabytes de memória, custava oito milhões de dólares (Lobur e Null, 2010). Esse cenário

dispendioso desacelerou a utilização da simulação geoestatística na mineração durante esse período, pois sua aplicação dependia de supercomputadores capazes de processar um grande volume de informação, que são dependentes entre si e tridimensionais, e não independentes e unidimensionais, como na simulação “clássica”.

Algumas soluções metodológicas foram desenvolvidas para amenizar esse problema. Matheron (1972; 1973) apresentou o método de simulação de bandas rotativas, que consiste em reduzir a simulação tridimensional para uma simples simulação unidimensional sobre linhas que retornam para o espaço em *3D*. Esse procedimento permitiu uma simulação *3D* com um custo computacional aceitável em comparação aos métodos de simulação “clássica”.

Journel (1974) apresentou a primeira aplicação dessa metodologia computacional em depósito mineral. Entretanto, além de aplicar o conceito de simulação não-condicional proposto por Matheron, emprega a concepção de simulação condicional sobre os dados. Deste modo, os resultados das simulações devem honrar os valores e a localização das amostras fornecidas. O objetivo da utilização desse método de simulação condicional por bandas rotativas foi fornecer informações sobre concentrações de teores de minério de níquel em uma malha compatível com o planejamento de lavra em curto prazo e com as previsões sobre o desempenho da planta de beneficiamento.

Somente a partir da quarta geração de computadores (1980 em diante), com o advento de tecnologias mais rápidas, menores e baratas que trouxeram imensos ganhos ao poder de processamento, a simulação geoestatística tornou-se operacionalmente viável. Desde então, vários novos métodos de simulação geoestatística surgiram, incluindo os aplicados em variáveis categóricas.

Journel e Isaaks (1984) aplicaram em um depósito de urânio a técnica dos indicadores, desenvolvida por Journel (1983) para o tratamento de variáveis extremas. Além disso, utilizaram os conceitos de normatização gaussiana sobre os dados. O propósito foi simular a variabilidade espacial da concentração de teores, condicionados pelas heterogeneidades do depósito. Essa simulação ainda utilizava o método de bandas rotativas em duas etapas para processar os dados.

Matheron *et al.* (1987) introduziram o método gaussiano truncado ao propor múltiplos truncamentos de uma função aleatória gaussiana, por diferentes valores limites, para reproduzir corretamente as proporções marginais de cada categoria. Isso permitiu variar a proporção de cada categoria, por exemplo, dentro de diferentes ambientes deposicionais ou dentro de uma seqüência estratigráfica. O método proposto foi aplicado em um reservatório de petróleo, com ambiente transicional fluvial deltaico, formado por três categorias de rochas sedimentares: arenito, siltito e argilito.

Davis (1987) propôs, pela primeira vez, a simulação condicional em uma única etapa com o método *LU* (*lower-upper*). Esse método é baseado na decomposição da matriz de covariância, em um processo conhecido como decomposição *LU*. Apesar de eficiente, esse método é limitado a variáveis que não excedam poucas ou centenas de localizações, devido à dimensão da matriz a ser decomposta.

Posteriormente, a contínua evolução tecnológica dos computadores e os métodos de simulação seqüencial viriam amenizar as dificuldades encontradas nesses métodos pioneiros da simulação geoestatística.

2.2.2. Simulação condicional seqüencial

Os métodos de simulação condicional seqüencial são baseados na decomposição da função de probabilidade acumulativa multivariada, $f(u_1, \dots, u_n; z_1, \dots, z_n)$, da função randômica $Z(u)$, em um produto distribuições condicionais univariadas (Issaks, 1990):

$$\begin{aligned}
 f(u_1, \dots, u_N; Z_1, \dots, Z_N) &= f(u_1; z_1) \\
 &* f(u_2; z_2 | Z(u_1) = z_1) \\
 &* \dots * f(u_N; z_N | z(u_j) = z_j, j = 1, \dots, N - 1)
 \end{aligned}
 \tag{2.5}$$

onde z_j é o valor atribuído a variável aleatória Z , na localização u_j . Portanto, os índices j , atribuídos a localização u , representam os N nós de grid a serem simulados ($j = 1, \dots, N$). Uma realização da função randômica $Z(u)$ é gerada quando todas as distribuições condicionais univariadas dos N nós de grid são conhecidas. Isso pode ser realizado por meio de uma seqüência

de tiragens aleatórias de cada distribuição condicional univariada. Essas tiragens são realizadas por meio da simulação de Monte Carlo. Em seguida, cada valor obtido dessa seleção randômica é utilizado para condicionar a próxima distribuição univariada, antes de a próxima tiragem ser executada. O processo termina quando a última distribuição univariada é condicionada e amostrada randomicamente. A rotina desses procedimentos é descrita a seguir:

- i. Tiragem aleatória de um valor a partir da distribuição acumulada $f(u_1; z_1)$ para realização z_1 da variável aleatória $Z(u_1)$;
- ii. A realização z_1 da variável aleatória $Z(u_1)$ passa a ser condicionante da distribuição univariada da variável aleatória $Z(u_2)$;
- iii. Tiragem aleatória de um valor a partir da distribuição marginal condicional $f(u_2; z_2 | Z(u_1) = z_1)$ para realização z_2 da variável aleatória $Z(u_2)$;
- iv. As realizações z_1 e z_2 são utilizadas como condicionantes da distribuição univariada da variável aleatória $Z(u_3)$;
- v. Tiragem aleatória de um valor a partir da distribuição marginal condicional $f(u_3; z_3 | Z(u_2) = z_2, Z(u_1) = z_1)$ para realização z_3 da variável aleatória $Z(u_3)$;
- vi. O processo continua em todas as demais localizações até que a última distribuição $f(u_N; z_N | Z(u_j) = z_j, j = 1, \dots, N - 1)$ seja condicionada;
- vii. Tiragem aleatória de um valor a partir da distribuição marginal condicional $f(u_N; z_N | Z(u_j) = z_j, j = 1, \dots, N - 1)$ para realização z_N da variável aleatória $Z(u_N)$.

Os resultados dessas etapas $\{z(u_j), j = 1, \dots, N\}$, gerados pelo algoritmo seqüencial, representam uma realização da função aleatória $Z(u)$ no espaço amostral original $z(u_\alpha)$ ($\alpha = 1, \dots, n$). A repetição desses passos por L vezes garante a geração de L realizações equiprováveis do modelo da função aleatória $Z(u)$ $\{z^{(l)}(u_j), j = 1, \dots, N; l = 1, \dots, L\}$. Portanto, em cada localização u_j ($j = 1, \dots, N$), o processo de simulação gera uma distribuição composta por L valores, que pode ser considerada uma aproximação numérica da distribuição condicional de probabilidade (método estocástico).

Imagens estocásticas do modelo da função aleatória $Z(u)$ podem ser geradas por meio de várias técnicas que utilizam o algoritmo seqüencial. As variações em torno desse algoritmo podem ser distinguidas pelo modelo de função de distribuição acumulada de probabilidades que for assumido para caracterizar o fenômeno geológico em estudo.

Na seção seguinte, serão apresentadas duas técnicas de simulação condicional seqüencial de variáveis categóricas, que foram aplicados na simulação de litotipos de depósitos de minério de ferro: (i) a simulação seqüencial dos indicadores, utilizada por Souza (2007) e Roldão *et al.* (2012); e (ii) a simulação de múltiplos pontos, aplicada por Osterholt (2006) e Pasti (2012).

2.3. Simulação de variáveis categóricas

2.3.1. Simulação seqüencial dos indicadores

Função de distribuição acumulada de probabilidades

A idéia dos indicadores (Journel, 1983) é reduzir os K resultados possíveis de uma variável aleatória categórica, para apenas duas possibilidades de um determinado evento ocorrer:

$$I_k(u) = \begin{cases} 1 & \text{se o evento } k \text{ ocorrer na localização } u \\ 0 & \text{caso contrário} \end{cases} \quad (2.6)$$

O evento k pode ser definido como a presença de fáceis, rochas ou solos do tipo k na localização u . A razão dessa transformação de variáveis aleatórias categóricas para indicadores é que os dados alterados podem ser avaliados como probabilidades condicionais:

$$\text{Prob}\{Z(u) = z_k | (n)\} \approx E[I(u; z_k) | I(u_\alpha; z_k) = i(u_\alpha; z_k), \alpha = 1, \dots, n] \quad (2.7)$$

onde, a função de probabilidade é igual à esperança condicional das variáveis aleatórias indicadoras $I(u; z_k)$, em relação aos dados condicionantes $i(u_\alpha; z_k)$.

A esperança condicional da variável aleatória $I(u; k_\alpha)$ da equação acima pode ser escrita em uma série expandida (Journel e Alabert, 1989):

$$\begin{aligned}
E[I(u; z_k)|I(u_\alpha; z_k) = i(u_\alpha; z_k), \alpha = 1, \dots, n] &= a_0 + \sum_{\alpha=1}^n a_1(u_\alpha) \cdot i(u_\alpha, z_k) \\
&+ \sum_{\alpha=1}^n \sum_{\alpha' \neq \alpha}^n a_2(u_\alpha, u_{\alpha'}) \cdot i(u_\alpha, z_k) \cdot i(u_{\alpha'}, z_k) \\
&+ \dots + a_n \prod_{\alpha=1}^n i(u_\alpha, z_k)
\end{aligned} \tag{2.8}$$

O conjunto de $n+1$ coeficientes (a_0, \dots, a_n) são determinados por meio de uma regressão linear múltipla dos dados indicadores desconhecidos $i(u; z_k)$, nas localizações não amostradas, sobre os n dados indicadores $i(u_\alpha; z_k)$ experimentais. De acordo com o teorema de projeção (Luenberger, 1969 *apud* Goovaerts, 1997), a estimativa por mínimos quadrados (krigagem) dos indicadores $i(u; z_k)$ é igual a estimativa por mínimos quadrados de sua esperança condicional. Nesse sentido, as probabilidades condicionais que constituem a função de distribuição acumulada $F(u; z|(n))$ podem ser determinadas por (co)krigagem dos indicadores em qualquer localização u não medida.

Medidas de conectividade

A simulação dos indicadores depende de uma função de covariância entre dois pontos para descrever a conectividade espacial dentro de cada zona estacionária A . Essa decisão de estacionaridade estrita implica que a direção de maior continuidade é a mesma para toda região A . A probabilidade desses dois indicadores separados por um vetor h se conectarem é:

$$\phi(h, z) = E\{I(u; z) \cdot I(u + h; z)\} \tag{2.9}$$

onde, a função de distribuição acumulada de uma variável aleatória ϕ é igual à covariância entre dois pontos.

Variograma

O variograma é a principal ferramenta geoestatística de medida de conectividade entre duas variáveis aleatórias. Considere duas VAs $Z(u)$ e $Z(u+h)$ separadas por um vetor h e pertencentes à função randômica estacionária $Z(u)$. A relação entre essas duas variáveis, em função do vetor de separação h , é caracterizada pela estatística de dois pontos por (Journel e Huijbregts, 1978):

(i) A covariância

$$C(h) = E\{[Z(u) - m][Z(u + h) - m]\} \quad (2.10)$$

(ii) O correlograma, ou coeficiente de correlação

$$\rho(h) = \frac{C(h)}{C(0)} \in [-1, +1] \quad (2.11)$$

(iii) O variograma

$$2\gamma(h) = E\{[Z(u + h) - Z(u)]^2\} = 2[C(0) - C(h), \text{se } C(h) \text{ existir}] \quad (2.12)$$

onde, $m = E\{Z(u)\}$, $C(0) = \sigma^2 = \text{Var}\{Z(u)\}$, representam estatística de $Z(u)$.

Alguns desses momentos entre dois pontos podem ser inferidos por uma estatística experimental correspondente, que é representada por $n(h)$ pares de dados $z(u_\alpha + h)$, $z(u_\alpha)$, $\alpha = 1, \dots, n(h)$, com distância aproximada h . O semivariograma $\gamma(h)$ experimentalmente definido como a esperança matemática do quadrado da diferença entre os valores de pontos no espaço, separados por uma distância h , é escrito como: (Issaks e Srivastava, 1989):

$$\gamma(h) = \frac{1}{2n(h)} \sum_{\alpha=1}^{n(h)} [z(u_\alpha + h) - z(u_\alpha)]^2 \quad (2.13)$$

Limitação

Essas medidas de conectividade baseadas na estatística de dois pontos, não conseguem capturar padrões de continuidade curvilíneos ou a presença de sub-regiões com direções de continuidade diferentes, pois a região estacionária A representada com uma covariância média mostra uma única direção média de continuidade. Deutsch (2002) investigou essa limitação por meio da reprodução, por simulação dos indicadores, de estruturas sedimentares, por exemplo, estratificações cruzadas formadas em ambiente deltaico. O autor concluiu que a estatística de dois pontos é inadequada para capturar algumas continuidades que não são lineares, pois os resultados da pesquisa mostraram que a reprodução dos padrões de controle curvilíneos das estratificações cruzadas foi insatisfatória (Figura 2.1).

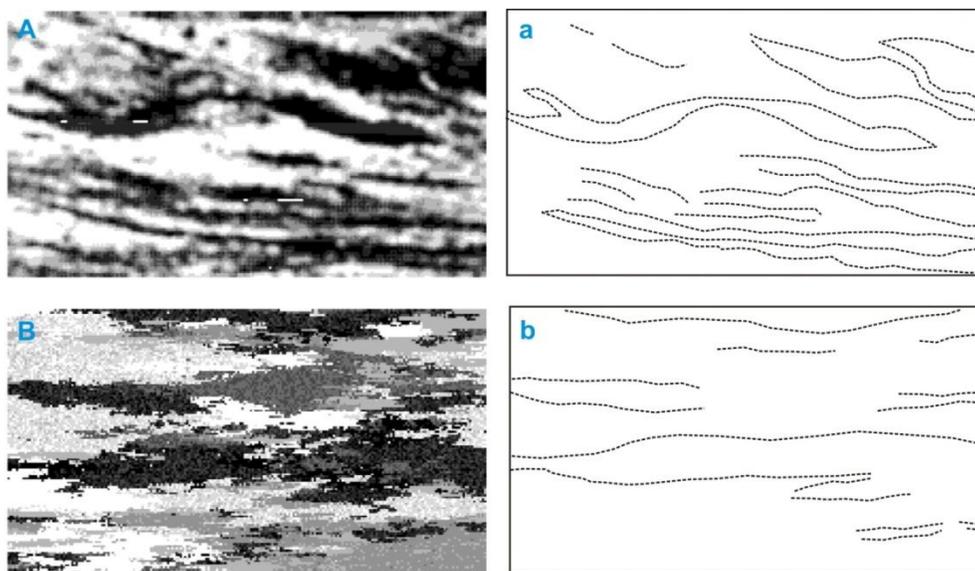


Figura 2.1. (A) estratificação cruzada acanaladas com alternância de camadas laminosas (claras) e arenosas (escuras); (B) resultado da simulação os indicadores; (a) e (b) interpretação das principais laminações das camadas escuras correspondentes a (A) e (B). (modificado de Deutsch, 2002).

Para esses casos, em que as características não lineares são essenciais para uma representação realística da distribuição espacial, duas alternativas podem ser utilizadas: (i) “relaxar” a decisão de estacionaridade separando a região A em subdomínios, cada um deles com direções de continuidade diferentes (Soares, 1990); e (ii) aplicar a estatística de múltiplos pontos para descrever a distribuição multivariada dentro de A (Guardiano e Srivastava, 1993). Nessa dissertação, somente a segunda alternativa será avaliada.

Algoritmo de simulação seqüencial dos indicadores (SISIM)

O algoritmo *SISIM* foi codificado segundo o método de simulação seqüencial dos indicadores, desenvolvido por Alabert (1987) e Journel (1989). A rotina operacional desse algoritmo pode ser resumida nos seguintes passos:

- i. Codificação binária da distribuição experimental $z(u_\alpha)$ ($\alpha = 1, \dots, n$) em um vetor $i(u_\alpha; z_k)$, onde ($\alpha = 1, \dots, n$) e ($k = 1, \dots, K$);

- ii. Cálculo dos covariogramas dos indicadores $C_I(h, z_k)$ para os K de valores limite z_k ;
- iii. Definição de um caminho aleatório, de modo que cada localização u_j ($j = 1, \dots, N$) desconhecida seja visitada somente uma única vez;
- iv. Construção da função de distribuição acumulada na localização u_j , via (co) krigagem, das probabilidades associadas a cada valor limite z_k ;
- v. Simulação, por meio de tiragem aleatória da função de distribuição acumulada (por simulação de Monte Carlo), de um valor da variável aleatória $Z(u_i)$, isto é: $z^{(l)}(u_j)$ ($l = 1, \dots, L$);
- vi. Inclusão de $z^{(l)}(u_j)$ no banco de dados, representando uma informação condicional adicional a ser utilizada nas demais localizações a serem visitadas;
- vii. Repetição das etapas (iv) e (vi) até que seja associada uma simulação a cada uma das N localizações; e
- viii. Repetição dos passos (iii) a (vii) para gerar L realizações equiprováveis da distribuição espacial da função aleatória $Z(u)$.

2.3.2. Simulação de múltiplos pontos

Função de distribuição acumulada de probabilidades

O método de simulação seqüencial dos indicadores, descrito anteriormente, constrói a função de distribuição acumulada $F(u; z|(n))$ por meio da (co)krigagem dos indicadores $i(u_\alpha; z_k)$ em qualquer localização u não medida $I(u; z_k)$. Geralmente, o algoritmo utilizado nessa estimativa $I(u; z_k)$ * é o de krigagem simples dos indicadores:

$$[I(u; z_k)]_{ksi}^* = \sum_{\alpha=1}^{n(u)} \lambda_\alpha(u; z_k) \cdot I(u_\alpha; z_k) + \left[1 - \sum_{\alpha=1}^{n(u)} \lambda_\alpha(u; z_k)\right] F(z_k), k = 1, \dots, K. \quad (2.14)$$

onde, a esperança condicional $E[I(u; z_k)]$ da variável aleatória $I(u; z_k)$ é igual a média dos indicadores e os λ_α são calculados a partir da resolução do sistema de krigagem:

$$\sum_{\beta=1}^{n(u)} \lambda_{\beta}(u; z_k) \cdot C_I(u_{\alpha} - u_{\beta}; z_k) = C_I(u_{\alpha} - u; z_k) \quad \alpha = 1, \dots, n(u) \quad (2.15)$$

No método de simulação de múltiplos pontos, a função de distribuição acumulada é construída, na localização u não medida, através da relação de *Bayes*:

$$Prob(I(u; z_k) = 1 | i(u_{\alpha}; z_k) = 1) = \frac{[Prob[I(u; z_k) = 1, i(u_{\alpha}; z_k) = 1]]}{Prob[i(u_{\alpha}; z_k) = 1]} \quad (2.16)$$

onde, $Prob(I(u; z_k) = 1 | i(u_{\alpha}; z_k) = 1)$ é igual a $[I(u; z_k)]_{ksi}^*$, conforme demonstrou Guardiano e Srivastava (1993).

Essa interpretação probabilística da krigagem simples dos indicadores permitiu acessar a conectividade espacial de múltiplos pontos pertencentes a um modelo exaustivo (imagem de treinamento), delimitados por um domínio τ_n e definidos por n vetores separados por h_1, \dots, h_n :

$$\phi(h_1, \dots, h_n; z) = E\{\prod_{\alpha=1}^n I(u + h_{\alpha}; k)\} \quad (2.17)$$

onde, $\phi(h_1, \dots, h_n; z)$ pode ser lido como a covariância entre múltiplos pontos separados por n vetores h_1, \dots, h_n (os vetores são os limites de τ_n).

Imagem de treinamento

A imagem de treinamento (*training image, ti*) é a ferramenta geoestatística utilizada para capturar a conectividade espacial entre os múltiplos pontos. A *ti* (como é conhecida) pode ser definida como um modelo conceitual, que imita os padrões espaciais e estruturais das heterogeneidades presentes em subsuperfície (Strebelle, 2002; Journel, 2004; Caers, 2011). Geralmente, a modelagem delas é baseada em afloramentos, imagens de sensoriamento remoto, modelos análogos e interpretação geológica. A distribuição espacial e o valor das amostras pertencentes a esses dados disponíveis não precisam ser honrados, caso sejam utilizados como modelos de referência. Uma *ti 3D* pode ser construída por algoritmos: (i) de objetos, por exemplo, os booleanos disponíveis no programa *Tigenerator* (Maharaja, 2007); ou (ii) tipo *CAD* presentes em programas de modelagem geológica.

Varredura da imagem de treinamento

Considere a Figura 2.2: (A) uma imagem de treinamento com duas categorias diferentes, representadas pelas cores Azuis e Brancas, distribuídas em tamanho de células regulares (*pixel*) exaustivamente; (B) um tamanho de molde (*template*) irregular formado por cinco células; (C) nove prováveis padrões encontrados por meio da varredura da imagem de treinamento; (D) uma árvore de possibilidades de cada célula ser Branca ou Azul com configurações diferentes; e (E) uma frequência de configurações possíveis (histograma de múltiplos pontos).

A seqüência descrita acima representa, esquematicamente, o processo de varredura da imagem de treinamento e da construção da função de probabilidade. Na prática, a varredura da ti é uma tarefa que pode exigir um grande volume de processamento. No caso mostrado, para um tamanho de molde de cinco células que podem assumir duas categorias diferentes foram encontradas 32 (2^5) configurações distintas. Assim dependendo do número de categorias e de tamanhos de molde o volume de informação processada pode ser expressivo. Por exemplo, para um molde em 3D com 125 células ($5 \times 5 \times 5$) que podem representar quatro categorias serão construídas 4^{125} configurações.

Árvore de busca

Guardiano e Srivastava (1993), seguindo os princípios da simulação seqüencial conforme descrito na seção 2.2, propuseram varrer a imagem de treinamento, para construção da função de distribuição de probabilidades, n vezes de acordo com a inclusão da estimativa dos valores não amostrados. Esse procedimento foi o principal responsável pelo insucesso operacional do algoritmo *ENESIM* (*Extended Normal Equation Simulation*) desenvolvido pelos autores.

Uma alternativa para esse problema de processamento foi apresentada por Strébel (2002) que propôs varrer a imagem de treinamento uma única vez e armazenar as configurações encontradas em um arquivo, chamado de árvore de busca (*search tree*), onde essas informações poderiam ser acessadas n vezes para cada estimativa de um ponto não amostrado. O autor demonstrou que esse procedimento não resultaria em perdas significativas para os resultados das simulações e que os ganhos computacionais eram expressivos. Essa técnica de armazenamento, incluída no algoritmo *SNESIM* (*Single Normal Equation Simulation*) desenvolvido pelo autor, possibilitou a operacionalidade do método de simulação de múltiplos pontos.

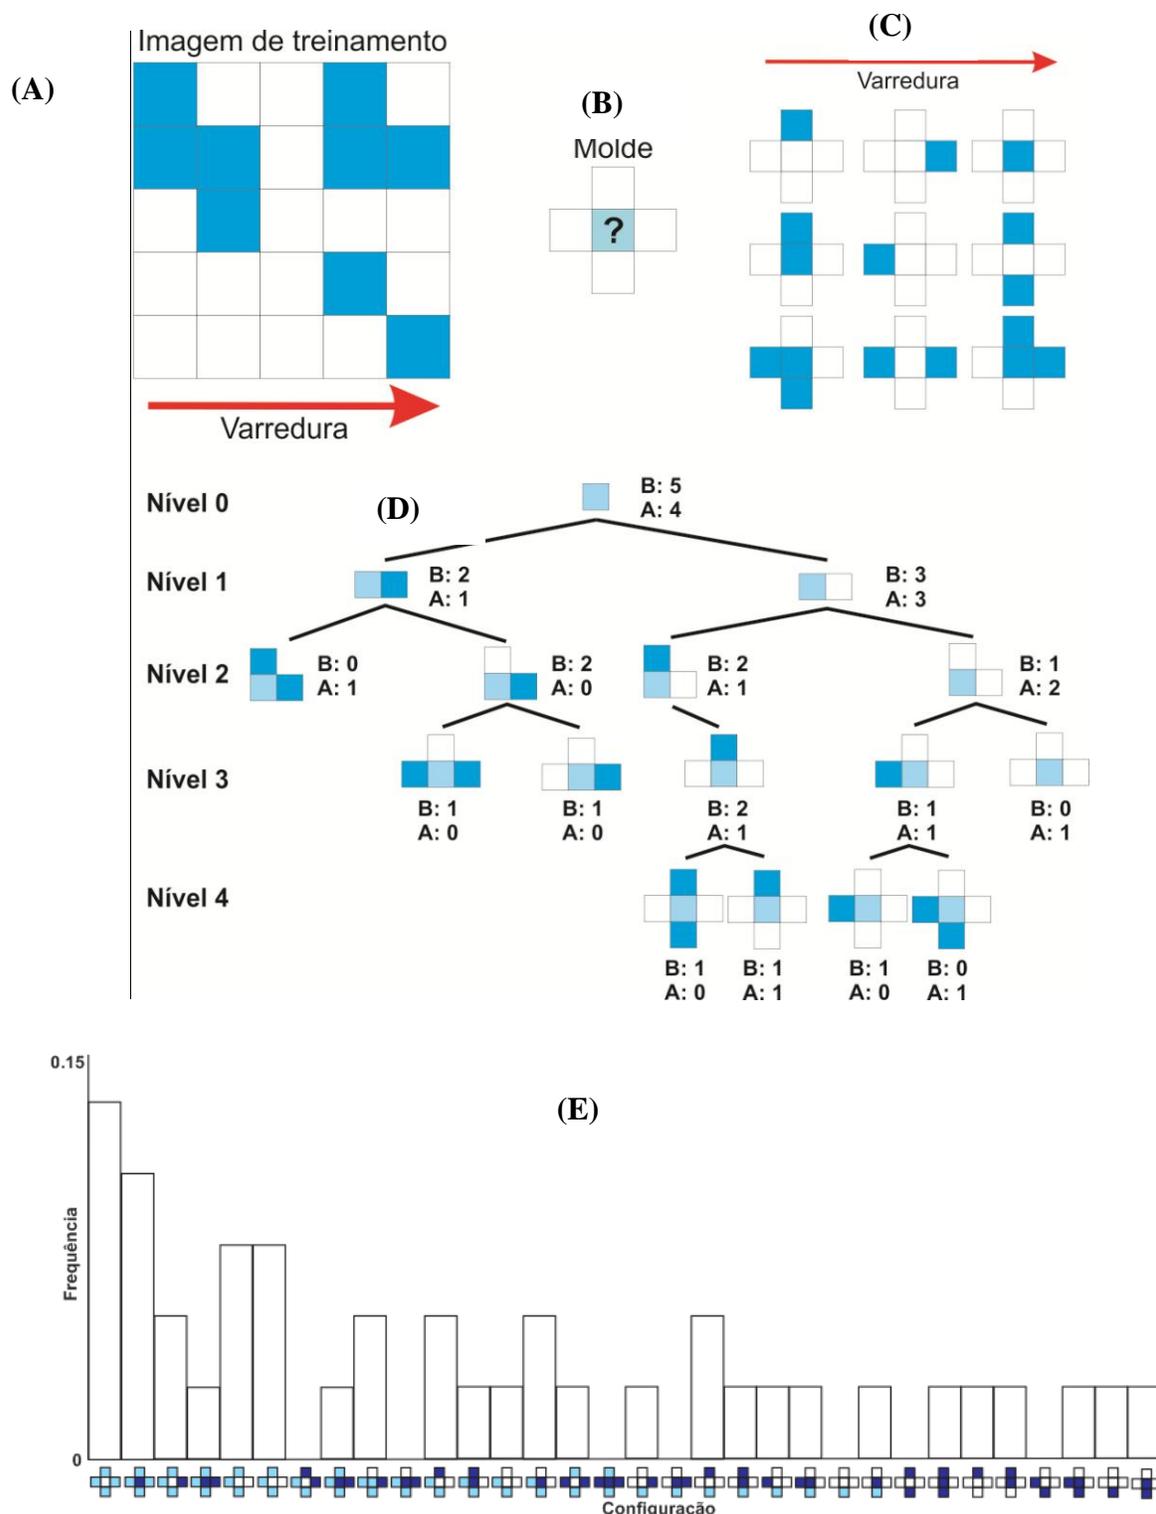


Figura 2.2: varredura da imagem de treinamento, (A) ti; (B) tamanho de molde; (C) freqüência dos possíveis moldes; (D) árvore de busca; e (E) freqüência (histograma de múltiplos pontos) das prováveis configurações (Branco = B; Azul escuro = A; Azul claro= desconhecido).

Algoritmo SNESIM

O algoritmo *SNESIM* segue os princípios de simulação seqüencial, sua rotina de processamento pode ser resumida nos seguintes passos:

- i. Varredura da imagem de treinamento para construção da árvore de busca dos dados correspondentes ao tamanho de molde escolhido $\tau_n = \{h_\alpha, \alpha = 1, \dots, n\}$;
- ii. Definição de um caminho aleatório, de modo que cada localização u_j ($j = 1, \dots, N$) desconhecida seja visitada somente uma única vez;
- iii. Construção da função de distribuição acumulada na localização u_j , via imagem de treinamento;
- iv. Simulação, por meio de tiragem aleatória da função de distribuição acumulada (armazenada na árvore de busca), de um valor da variável aleatória $z(u)$;
- v. Inclusão da variável estimada no banco de dados, representando uma informação condicional adicional a ser utilizada nas demais localizações a serem visitadas;
- vi. Repetição da etapa (iv) até que seja associada uma simulação a cada uma das N localizações; e
- vii. Repetição dos passos (iv) a (vi) para gerar L realizações equiprováveis da distribuição espacial da função aleatória $Z(u)$.

Capítulo 3

Testes e comparações

Na literatura científica, os parâmetros do algoritmo *SNESIM*, na maioria dos casos, foram ajustados para modelagem de reservatório de petróleo. Estudos em que esses parâmetros são testados para modelagem de depósitos minerais são raros. Devido à escassez de informação sobre os parâmetros de simulação, via algoritmo *SNESIM*, aplicados em depósitos minerais; este capítulo testa e avalia os principais parâmetros do algoritmo investigado nesse tipo de ambiente geológico. Neste sentido, é desenvolvido um estudo de caso do banco de dados *Walker Lake*, por meio do programa de modelagem geoestatística *SGeMS**, desenvolvido na Universidade de *Stanford* e com código- fonte aberto. Além disso, os resultados das simulações construídas por algoritmo *SISIM* e *SNESIM* são comparados, o propósito é avaliar as diferenças na reprodução dos padrões gerados por cada um deles. A seção 3.1 faz uma análise de sensibilidade sobre os parâmetros utilizados no algoritmo *SNESIM*. A seção 3.2 compara os algoritmos *SISIM* e *SNESIM* com o banco de dados exaustivo. A seção 3.3 discute os resultados.

Walker Lake

Isaaks e Srivastava (1989), a partir de dados originais, criaram dois bancos de dados: um chamado de exaustivos que abrange 78.000 dados; e o outro, correspondente as amostras com 470 dados. Três conjuntos de variáveis estão disponíveis nesses bancos: *V*, *U* e *T*. As duas primeiras são variáveis contínuas e a última categórica. Nesta dissertação, as amostras pertencentes ao grupo de variáveis categóricas foram identificadas como: estéril representado pelo indicador 0; e minério com indicador 1. O propósito foi desenvolver um estudo de caso para avaliar os métodos apresentados. A Figura 3.1 mostra que a proporção desses indicadores é de 90% de estéril e 10% de minério e que estão distribuídos em malha irregular, com agrupamentos preferenciais em alguns locais.

* <http://sgems.sourceforge.net> (versão 2.1, 64 bits)

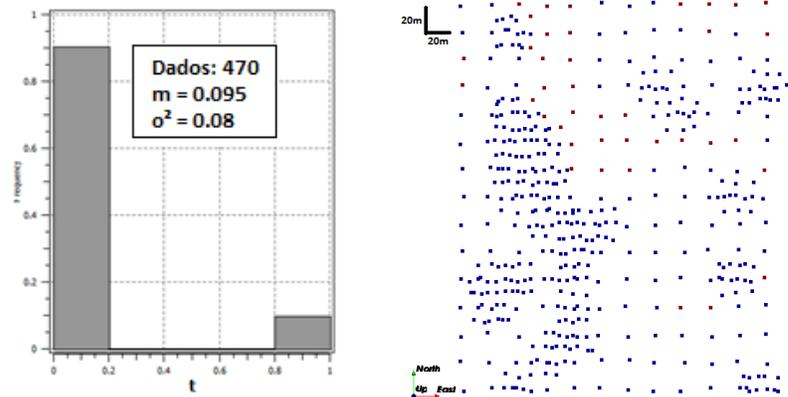


Figura 3.1: freqüência relativa dos indicadores com o respectivo sumário estatístico; e mapa de localização do estéril (azul) e minério (vermelho).

3.1. Análise de sensibilidade dos parâmetros do algoritmo *SNESIM*

3.1.1. Reproduzindo padrões

A idéia principal da simulação de múltiplos pontos é condicionar as variáveis aleatórias desconhecidas aos padrões “morfológicos” da imagem de treinamento de modo que honrem as amostras (n). Os algoritmos de múltiplos pontos mostram que uma imagem de treinamento não é um modelo análogo do depósito, mas um repositório de padrões e probabilidades (Boucher, 2009).

Devido essa importância sobre os resultados, é freqüente a dúvida sobre qual imagem de treinamento utilizar na simulação. A resposta óbvia para essa pergunta seria empregar uma imagem que reproduza melhor os padrões para a simulação. Entretanto, a prática tem mostrado que a reprodução dos padrões não depende somente da imagem de treinamento. Com o propósito de investigar o impacto dos parâmetros sobre a reprodução dos padrões e, conseqüentemente, sobre a escolha da imagem de treinamento, foram construídas três imagens de treinamento com proporções de minérios e padrões geométricos diferentes, que serão testadas e avaliadas: a primeira representa um corpo com 87.5% de estéril e 12.5% de minério com forma (pseudo) circular; a segunda imagem tem 67.5% de estéril e 32.5% de minério com geometria continua e inclinação aparente; e a última delas apresenta uma proporção de 74% estéril e 26% minério com formato continuo e (pseudo) elíptico (Figura 3.2).

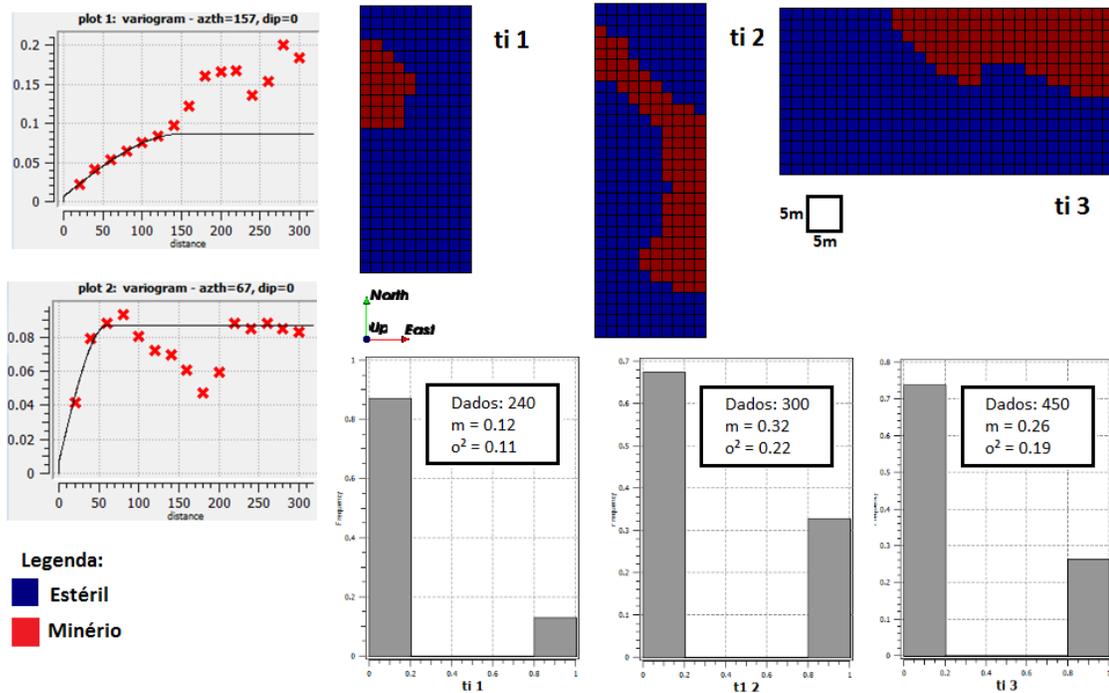


Figura 3.2: imagens de treinamento com os respectivos histogramas. (ti 1= imagem de treinamento um; ti 2= imagem de treinamento dois; ti 3= imagem de treinamento três); e variogramas de maior (acima) e menor (abaixo) continuidade espacial.

Molde (template)

Muitas vezes, confunde-se a escolha do tamanho de molde (*template*) com a modelagem do variograma. Em alguns casos, modela-se primeiro o variograma para definir a direção de maior e menor continuidade geométrica e os respectivos alcances, para depois decidir sobre as dimensões e direções do molde. Para avaliar o efeito dessa prática, foram escolhidos três tamanhos de molde: (i) dimensões de 30x30 (m), isotrópico, e azimute 0; (ii) tamanho de 150x60 (m) e azimute 157; e (iii) dimensões de 50x20 (m) e azimute 0. Estes últimos tamanhos anisotrópicos foram escolhidos em função do variograma dos dados. O tamanho 50x20 (m) e proporcional aos alcances de 150 m e 60 m e a direção de 157 é corresponde a maior continuidade geométrica dos dados (Figura 3.2).

Os resultados mostraram que: no caso (i) a imagem de treinamento dois (ti 2) reproduziu uma conectividade maior entre as categorias minério (cor amarelo) na direção Norte, Oeste, Sul,

Leste, em comparação aos resultados gerados com outras imagens de treinamento; nos casos (ii) e (iii) nenhuma realização reproduziu satisfatoriamente a conectividade entre as categorias minério. Nestes casos, o molde isotrópico e a imagem de treinamento dois (com padrões de geometria contínua e inclinação aparente) reproduziram um resultado mais satisfatório.

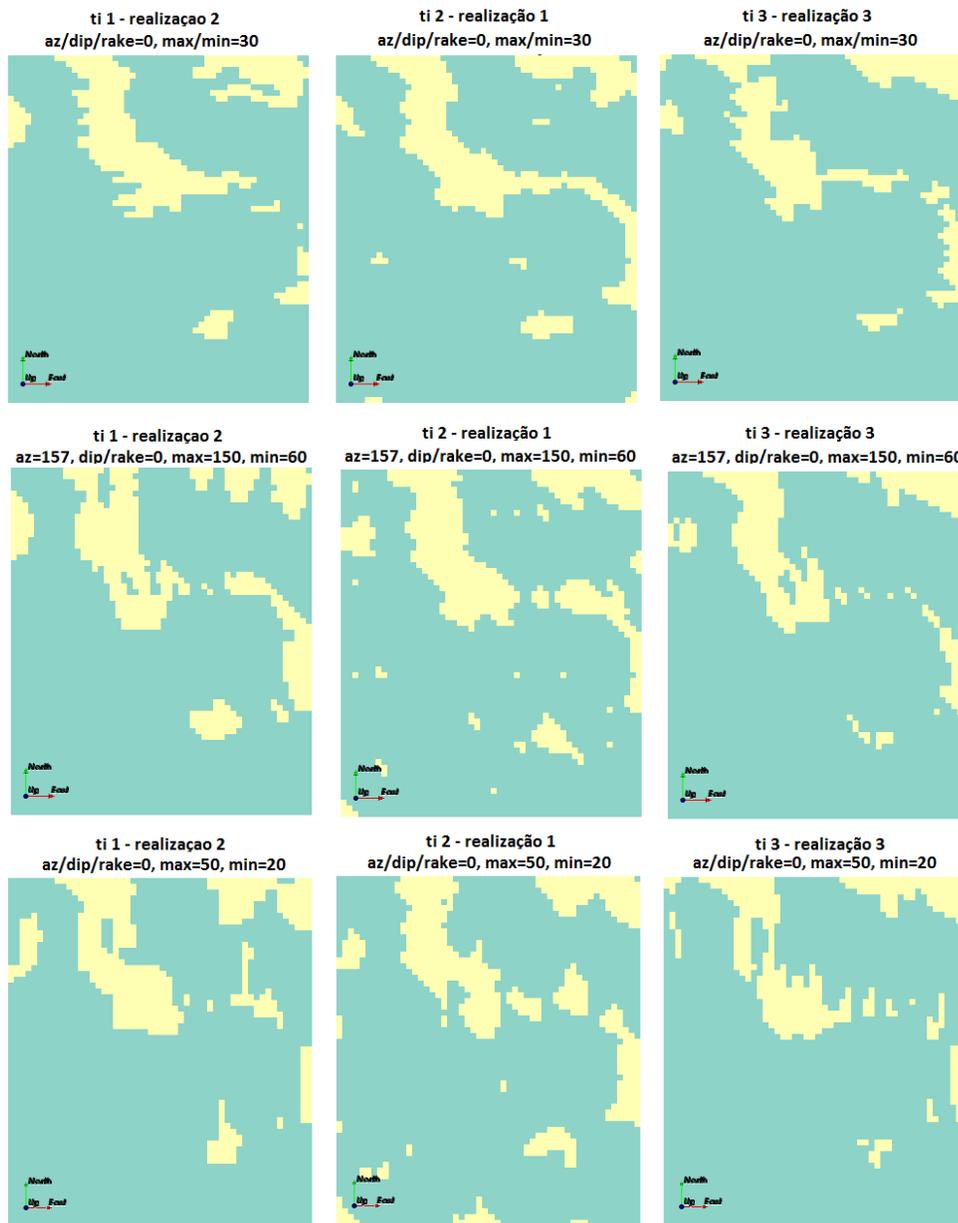


Figura 3.3: resultados das simulações com imagem de treinamento e tamanhos e/ou direções de moldes diferentes. (*az*= azimute; *dip*= mergulho; *rake*= obliquidade; *max*= alcance máximo; e *min*= alcance mínimo).

Múltiplos moldes

A técnica de múltiplos moldes foi desenvolvida como solução para a limitação que um único molde de varredura, relativamente pequeno, tem em capturar padrões mais longos e contínuos da imagem de treinamento. A Figura 3.4 mostra o resultado do algoritmo aplicado em uma imagem de treinamento binária de tamanho 250 x 250 (m), que utiliza tamanhos de moldes de 9 x 9 (m) e 35 x 35 (m). Quando o molde menor 9 x 9 (m) foi usado, o algoritmo satisfatoriamente reproduziu todos os detalhes de escalas menores da imagem de treinamento, mas os padrões de escala maiores (por exemplo, as estruturas de canais) não foram reproduzidos. O molde maior de 35 x 35 (m) reproduziu melhor as estruturas contínuas, apresentando um resultado satisfatório. Entretanto, a utilização de tamanhos de molde maiores aumenta o tempo total de processamento computacional. Neste exemplo, que foi apresentado por Arpat e Caers (2007), o aumento do tamanho do molde representou um acréscimo no tempo de processamento do algoritmo de 15 vezes.

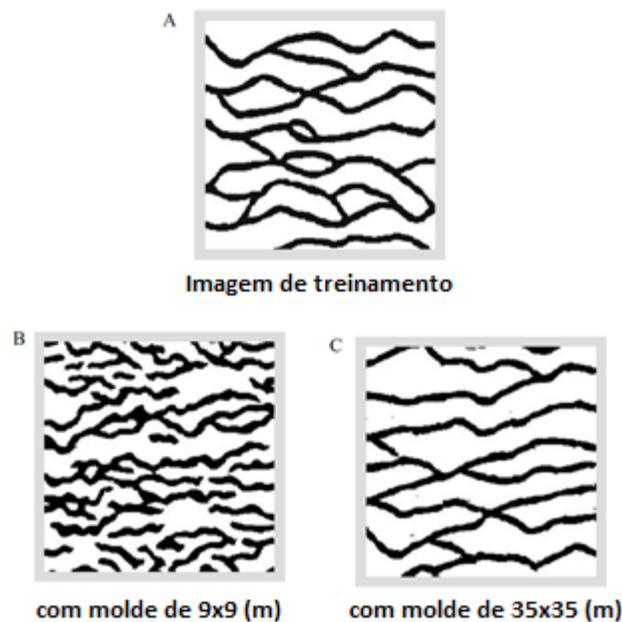


Figura 3.4: limitação do molde em reproduzir estruturas longas (em preto) satisfatoriamente; (A) imagem de treinamento; (B) simulação realizada a partir de um único molde de varredura com tamanho de 9x9 (m); e (C) um único molde de varredura com tamanho de 35x35 (m). Fonte: Arpat e Caers (2007).

Uma alternativa para os problemas apresentados de reprodução de padrões contínuos e de eficiência no processamento foi apresentada por Strebéle (2002). O autor propõe capturar os padrões de estruturas mais longas a partir de moldes de busca maiores, mas com razoável (pequeno) número de nós, que varrem a imagem de treinamento simultaneamente. Os padrões varridos de menor e maior conectividade são armazenados na árvore de busca. Deste modo, o algoritmo acessa essas informações e decide como reproduzi-las. Este processo é mostrado na Figura 3.5. Um molde maior de tamanho 5x5, não exaustivo (com vários nós ausentes), captura os padrões de estrutura mais alongados, enquanto um molde menor de dimensão 3x3, exaustivo, captura os padrões de escala menores. Os padrões capturados são armazenados na árvore de busca e são reproduzidos pelo algoritmo. O resultado são padrões de canais alongados (em preto) reproduzidos satisfatoriamente.

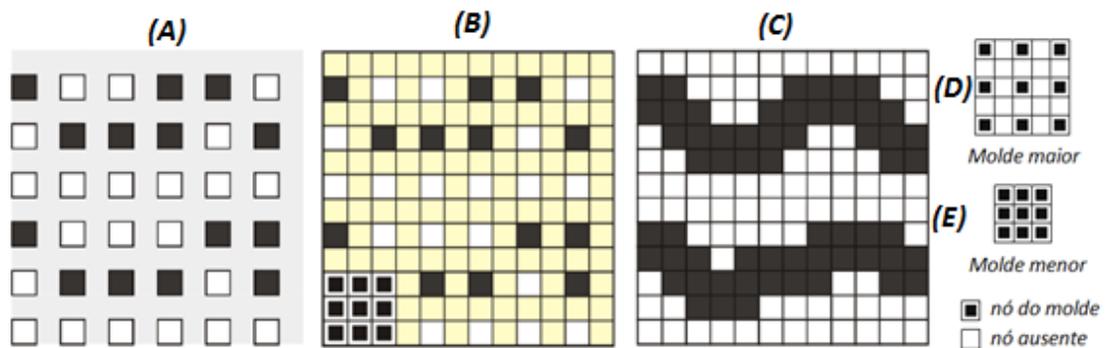


Figura 3.5: múltiplos de moldes de busca; (A) reprodução dos padrões capturados pelo molde maior (D); (B) reprodução dos padrões capturados pelo molde menor (E); e (C) resultado da simulação ao acessar (A) e (B).

Nestes casos, onde múltiplos moldes devem ser utilizados, a dúvida mais freqüente é: qual é o melhor número de moldes necessário para reproduzir os padrões mais alongados? Para responder tal pergunta, diferentes números de moldes foram testadas.

Os resultados mostram que independente do número de moldes, as simulações com a primeira e terceira imagem de treinamento não tiveram mudanças significativas. Este resultado era esperado, uma vez que essas imagens de treinamento não apresentam um padrão de distribuição alongado. Para as simulações realizadas com a segunda imagem de treinamento, os resultados foram afetados pelo número de moldes. Quando apenas um molde foi utilizado, a

continuidade não foi satisfatoriamente reproduzida; na realização com três moldes, o padrão característico com maior conectividade entre as categorias minério (cor amarelo) na direção Norte, Oeste, Sul, Leste foi reproduzido; e com cinco malhas, não ocorreu ganho no resultado em relação ao número de moldes anterior (Figura 3.6).

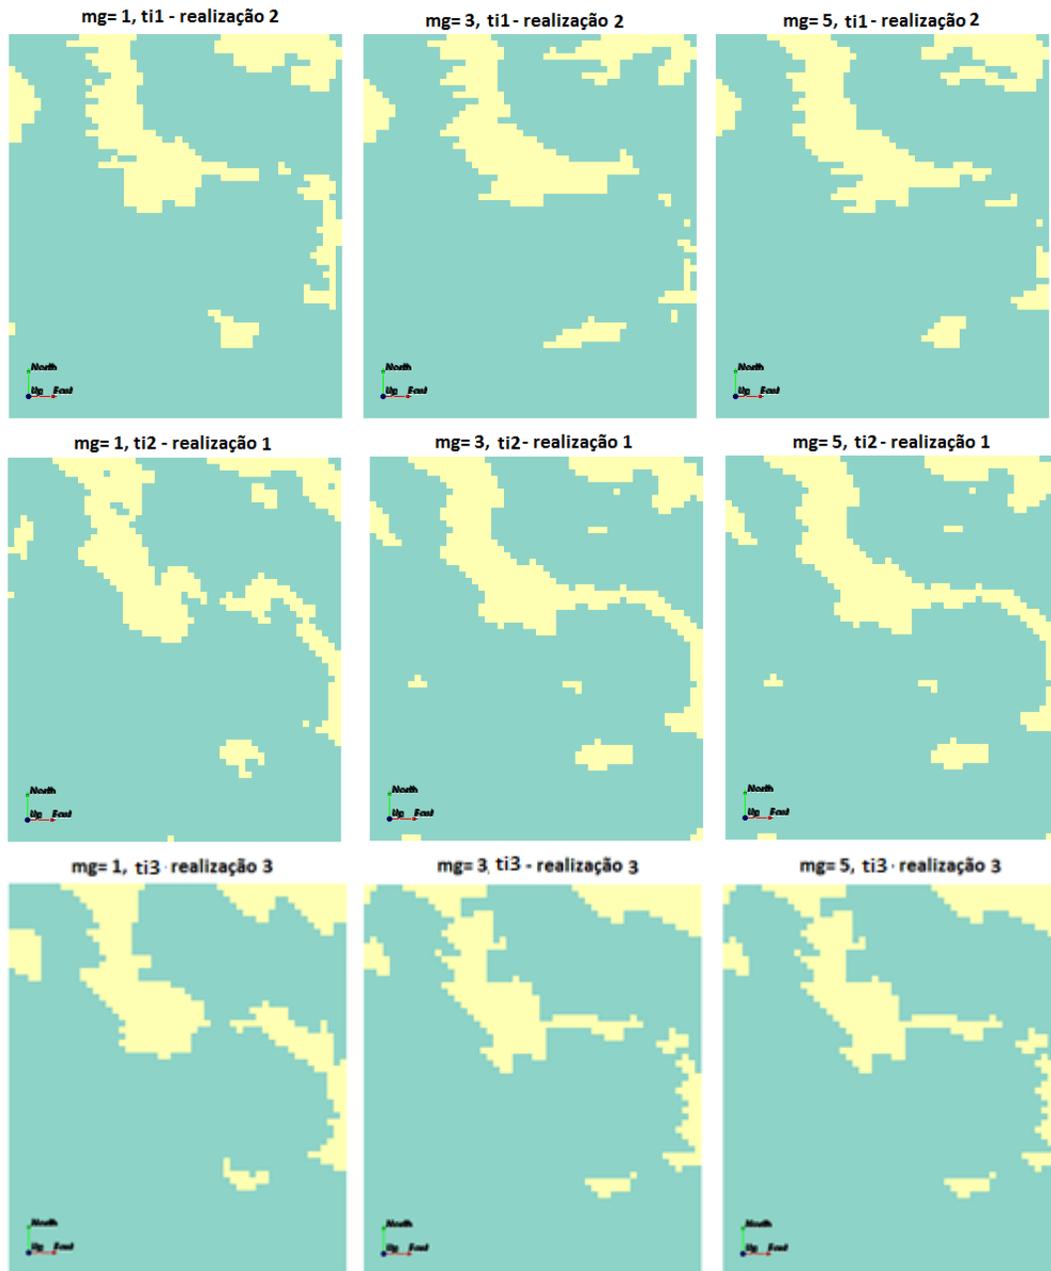


Figura 3.6: resultados das simulações com imagem de treinamento e número de malhas diferentes. (mg = múltiplos moldes).

3.1.2. Reproduzindo proporções

Fator servosystem

O algoritmo *SNESIM* dispõe de um fator capaz de ajustar as proporções das categorias de acordo com os resultados esperados. As proporções desejadas são informadas na distribuição marginal padrão. Geralmente, essas proporções são de amostras primárias ou da imagem de treinamento. O fator *servosystem*, como é denominado, permite controlar ou corrigir essas proporções informadas.

Para responder as dúvidas: qual distribuição marginal informar? Que valor de fator de ajuste utilizar? Foram testados fatores de ajuste e distribuições diferentes nas simulações. O propósito é avaliar os efeitos dessas informações sobre as simulações. Quando são informadas as proporções de estéril (85%) e minério (15%) das amostras originais (*hard data*) como distribuição marginal, os resultados mostram que as proporções de minério e estéril nas realizações com fatores iguais a 0, 0.25 e 0.5 mantiveram-se, relativamente, similares entre si e tiveram uma redução de aproximadamente 2.5% de estéril e acréscimo proporcional de minério. Fatores de ajuste maiores, 0.75 e 1, honraram mais a proporção dos dados (Tabela 3.1).

Nos casos em que são informadas as proporções de estéril e minério das imagens de treinamento como distribuição marginal, os resultados mostram que: (i) as proporções da imagem de treinamento (ti1) de 87,5% de estéril e 12,5% de minério, não são reproduzidas em nenhum resultado, as proporções das realizações para os fatores 0, 0.25, 0.5 e 0.75 apresentam uma redução aproximada de 5.15% de estéril e aumento de 36,5% de minério (superestimativa); (ii) as proporções da (ti2) de 67,5% de estéril e 32,5% de minério, não são reproduzidas em nenhum resultado, as proporções das realizações para os fatores 0, 0.25 e 0.5 apresentam um acréscimo de 20% de estéril e uma redução de 23.5% de minério (subestimativa), os fatores 0.75 e 1 provocam um acréscimo de 13.5% de estéril e uma redução de 7.5% de minério (subestimativa) ; e a (iii) as proporções da (ti3) de 74% de estéril e 26% de minério, não são reproduzidas em nenhum resultado, as proporções das realizações para os fatores 0, 0.25, 0.5 e 7.5 apresentam um acréscimo de 9.5% de estéril e uma redução de 23% de minério (subestimativa), o fator de ajuste 1 gera um acréscimo de 2.7% de estéril e uma redução de 7.7% de minério (Tabela 3.2).

Tabela 3.1: proporções de minério e estéril das simulações com imagens de treinamento, distribuições marginais e fatores de ajuste diferentes. (*sf*=fator; *est%*= estéril; *min%*= minério; *target hd*= proporções marginais correspondente às amostras primárias).

<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)	<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)	<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)
target hd, ti 1			target hd, ti 2			target hd, ti 3		
0.0	83	17	0.0	82	18	0.0	82	18
0.25	83	17	0.25	83	17	0.25	83	17
0.5	83	17	0.5	83	17	0.5	83	17
0.75	83	17	0.75	83	17	0.75	85	15
1.	86	14	1.	85	15	1.	87	13

Tabela 3.2: proporções de minério e estéril das simulações com imagens de treinamento, distribuições marginais e fatores de ajuste diferentes. (*sf*=fator; *est%*= estéril; *min%*= minério; *target ti*= proporções marginais correspondentes às imagens de treinamento).

<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)	<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)	<i>sf</i>	<i>est</i> (%)	<i>min</i> (%)
target ti 1, ti 1			target ti 2, ti 2			target ti 3, ti 3		
0.0	83	17	0.0	81	19	0.0	82	18
0.25	83	17	0.25	80	20	0.25	82	18
0.5	83	17	0.5	79	21	0.5	81	19
0.75	83	17	0.75	77	23	0.75	80	20
1.	84	16	1.	75	25	1.	77	23

3.2. SISIM vs. SNESIM

Neste estudo comparativo, oito variogramas foram modelados nas principais direções de anisotropia geométrica, e evidenciaram que as direções de maior e menor continuidade encontradas são de $N157^\circ$ e $N67^\circ$, respectivamente (Figura 3.2). Os parâmetros utilizados na modelagem são apresentados na Equação:

$$\gamma(h_x, h_y) = 0,0067 + 0,08 \left(\sqrt{\left(\frac{h_x}{150}\right)^2 + \left(\frac{h_y}{60}\right)^2} \right) \quad (3.1)$$

A imagem de treinamento foi escolhida a partir da análise de sensibilidade apresentada na seção anterior. Os resultados mostraram que a segunda imagem de treinamento (ti2) foi a que melhor reproduziu os padrões de continuidade entre as categorias minério na direção Norte, Oeste, Sul, Leste em comparação com os resultados gerados por outras imagens de treinamento (Figura 3.7).

A comparação visual entre os resultados das simulações geradas e os dados exaustivos do banco de dados *Walker Lake* mostram que: o algoritmo *SISIM* não reproduziu satisfatoriamente as características curvilíneas do minério e apresentou contornos de bordas difusos; enquanto, o algoritmo *SNESIM* conseguiu reproduzir os padrões curvilíneos do minério e contornos de margens pouco ruidosos (Figura 3.8). Portanto, os resultados atestam um desempenho visual melhor das realizações por *SNESIM*.

A reprodução das proporções, para uma distribuição marginal de 85% de estéril e 15% de minério (dados originais) e fator de ajuste de 0.5, foi de aproximadamente 81,5% de estéril e 18,5% de minério para o algoritmo *SISIM*; e de 82,5% de estéril e 17,5% de minério para o algoritmo *SNESIM*. Quando comparados com as proporções dos dados exaustivos de 84% de estéril e 16% de minério, observa-se que ocorreram: (i) redução de 3% de estéril e acréscimo de 15,5% de minério (superestimativa) na realização 51 por *SISIM*; e (ii) redução de 1,8% de estéril e acréscimo de 9,3 % de minério (superestimativa) na realização 43 por *SNESIM*. Ambos os resultados não reproduziram satisfatoriamente as proporções dos dados exaustivos, para o caso do algoritmo *SNESIM* sugere-se aumentar o fator de ajuste de modo que as proporções informadas possam ser honradas.

Uma diferença significativa entre os algoritmos testados foi o desempenho de processamento (ver Anexo A). Para completar cem realizações o *SISIM* demorou 5,93 s; enquanto, o *SNESIM* precisou de 3,37 s para executar a mesma tarefa. Esta diferença de processamento de aproximadamente 45% é resultante da forma que os algoritmos acessam a função de distribuição de probabilidades. O algoritmo *SISIM* para cada valor não amostrado constrói uma função de probabilidade, enquanto o *SNESIM* acessa a função de probabilidades armazenada na árvore de busca para todos os pontos não amostrados.

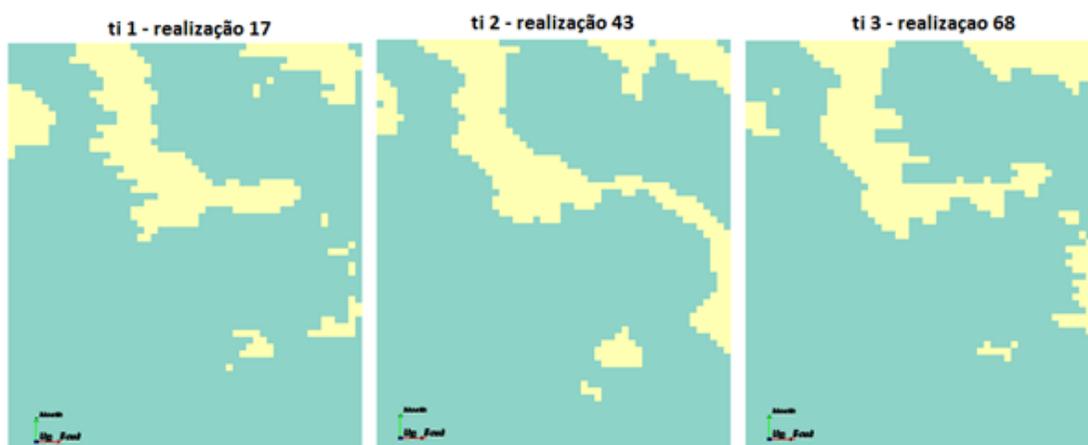


Figura 3.7: resultados das simulações com diferentes imagens de treinamento.

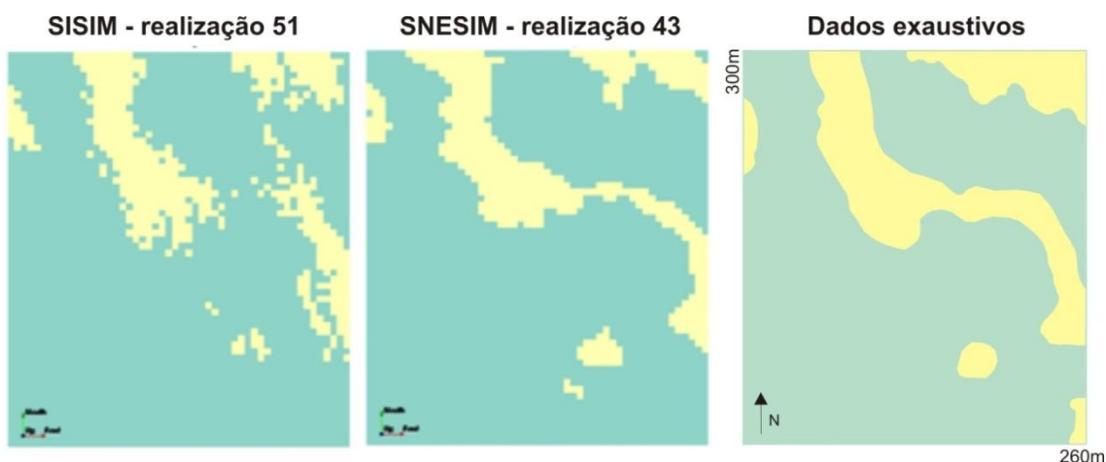


Figura 3.8: comparação entre os resultados das simulações geradas pelo algoritmo *SISIM* e *SNESIM*, e os dados exaustivos do banco de dados *Walker Lake* (imagem modificada de Issaks e Srivastava (1989)).

3.3. Discussões

A escolha da imagem de treinamento (*ti*) foi crucial para os resultados. Na construção delas, a *ti* não foi interpretada como um modelo análogo ao depósito, mas como um repositório de padrões (Figura 3.2). Diferentes padrões foram testados e comparados. Embora, a *ti* tenha sido um parâmetro crítico para definir o modelo estrutural do depósito, não foi o único. Dada a mesma

ti, mudando o número de múltiplas malhas ou variando o tamanho do molde alterou-se, consideravelmente, os padrões gerados pelo algoritmo *SNESIM* (Figuras 3.3 e 3.4). Portanto, os resultados evidenciam que os parâmetros de varredura são tão importantes quanto os padrões presentes na imagem de treinamento para gerar resultados satisfatórios.

A decisão sobre os parâmetros de distribuição marginal padrão e fator de ajuste dependem do conhecimento do modelador sobre o depósito estudado. Na modelagem de reservatório de petróleo, onde as amostras primárias são escassas, é conveniente utilizar a proporção da imagem de treinamento. Na modelagem de depósitos minerais, onde pode haver abundância de amostras advindas das sondagens, pode-se utilizar a proporção das amostras primárias com fatores de ajuste menores. A escolha errada desses parâmetros pode gerar resultados superestimados ou subestimados (Tabela 3.1 e 3.2).

Comparativamente, os algoritmos apresentaram desempenhos diferentes. O *SISIM* gerou realizações difusas nas bordas do minério, não reproduziu satisfatoriamente os padrões curvilíneos e demorou mais para processar as cem realizações. Enquanto, que o *SNESIM* reproduziu os padrões curvilíneos, não apresentou ruídos nas bordas e foi mais eficiente no processamento (Figura 3.8). Esses resultados sugerem que aplicação da geoestatística de múltiplos pontos por *SNESIM* pode ser promissora para modelagem geológica de depósitos.

Capítulo 4

Simulação de litotipos de depósitos de minério de ferro com *SNESIM*: desafios e soluções

Os principais desafios encontrados nessa dissertação e na literatura científica para aplicação do algoritmo *SNESIM* em depósitos de minério de ferro serão apresentados nesse capítulo. Além disso, algumas soluções para esses problemas práticos serão discutidas. O objetivo é, a partir da análise de cada solução mostrada, propor uma metodologia para abordagem do problema. A seção 4.1 apresenta algumas técnicas de integração de informações geológicas no algoritmo *SNESIM* aplicadas em depósitos de ferro. A seção 4.2 propõe uma metodologia capaz de adicionar essas informações geológicas como dados secundários em mapas de probabilidade.

4.1. Integração de informações geológicas

Alguns depósitos podem apresentar uma arquitetura fortemente controlada por processos tectônicos ou estratigráficos de escala regional, tais como, descontinuidades estruturais ou continuidades estratigráficas de grande extensão. Essas informações adicionais, sobre o processo de formação do depósito, permitem que extensas regiões sejam interpretadas sem a necessidade de furos adicionais de sondagem. É comum que haja regiões do depósito mais amostradas do que outras. Geralmente, as áreas densamente amostradas são os corpos mineralizados (minério) e as áreas de maior complexidade geológica. Essa distribuição amostral é comum em depósitos de minério ferro, que se depositaram em extensas bacias sedimentares com regiões bem definidas de estéril.

A ausência de amostras em grandes extensões do depósito, não resulta em nenhum prejuízo do ponto de vista operacional para a modelagem geológica tradicional, pois essas informações geológicas são integradas ao computador de forma manual, e não automática como

ocorre nos algoritmos de simulação geoestatística. Essa distribuição com áreas densamente amostradas em detrimento outras regiões extensas não amostradas é prejudicial para operacionalização da modelagem geológica automática de depósitos minerais complexos via algoritmos *SNESIM*. Uma vez que, as decisões do algoritmo são baseadas nas amostras e nos padrões modelados na imagem de treinamento, e não no conhecimento geológico regional ou local da área de interesse.

Para exemplificar essa limitação do algoritmo em relação à configuração das amostras, o banco de dados *Walker Lake* apresentado no Capítulo 3 foi novamente modificado. Desta vez, foi criado um novo banco de dados com 95 amostras distribuídas em uma região preferencial do depósito em detrimento de outras não amostradas, de acordo com o cenário amostral apresentado no parágrafo anterior (Figura 4.1).

O algoritmo *SNESIM*, com mesmos os parâmetros utilizados e a imagem de treinamento selecionada no capítulo anterior (exceto o banco de dados, que agora foi reduzido), reproduziu nessas extensas regiões não amostradas os padrões da imagem de treinamento, uma vez que as informações geológicas interpretadas não foram integradas nas simulações realizadas (Figura 4.1).

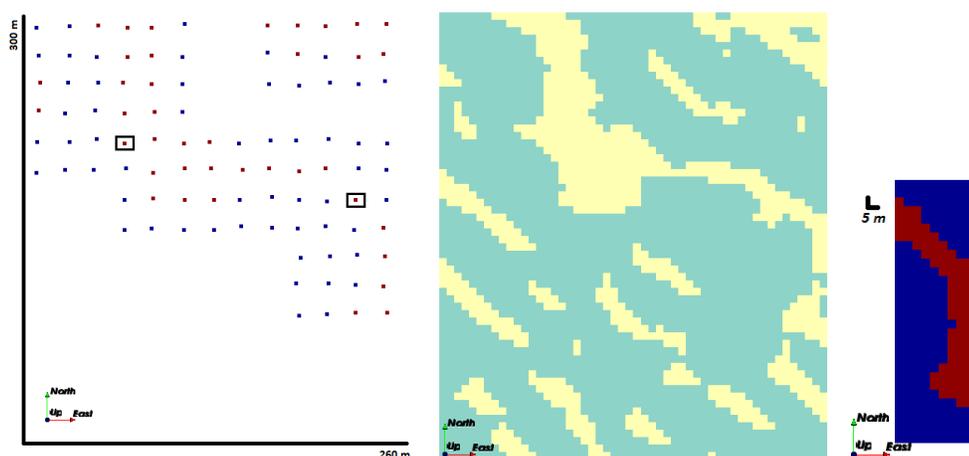


Figura 4.1: distribuição das amostras do banco de dados Walker Lake modificado, os retângulos identificam as amostras retiradas do banco e, posteriormente, usadas na etapa de validação (esquerda); e resultado de uma simulação por *SNESIM* e a imagem de treinamento utilizada (direita). (vermelho / amarelo = minério; azul / verde = estéril).

Na literatura científica, existem dois estudos de casos, aplicados na modelagem geológica de depósitos de minério de ferro, que apresentam alternativas para resolver esse problema de integração de informações geológicas. O primeiro desses trabalhos foi apresentado por Osterholt (2006) que simulou a geologia de um depósito australiano, que apresentava uma distribuição amostral densa em algumas áreas e ausente em outras. O segundo estudo mostrado por Pasti (2012) simulou um depósito de ferro brasileiro com uma distribuição das amostras similar a do trabalho anterior. Ambos os autores tiveram problemas em aplicar o algoritmo, sem utilizar dados artificiais (informações além das contidas na base de dados de sondagens) que integrassem as informações geológicas necessárias para simular a geologia do depósito de forma satisfatória.

Osterholt (2006) construiu vários furos “fantasmas” identificados como estéril e distribuídos em malha regular nas regiões não amostradas. Em seguida, adicionou cada um deles aos dados originais (Figura 4.2). Os resultados desse procedimento foram visualmente satisfatórios, pois o algoritmo processou as informações adicionais como verdadeiras e reproduziu essa probabilidade nos locais que anteriormente não eram amostrados.

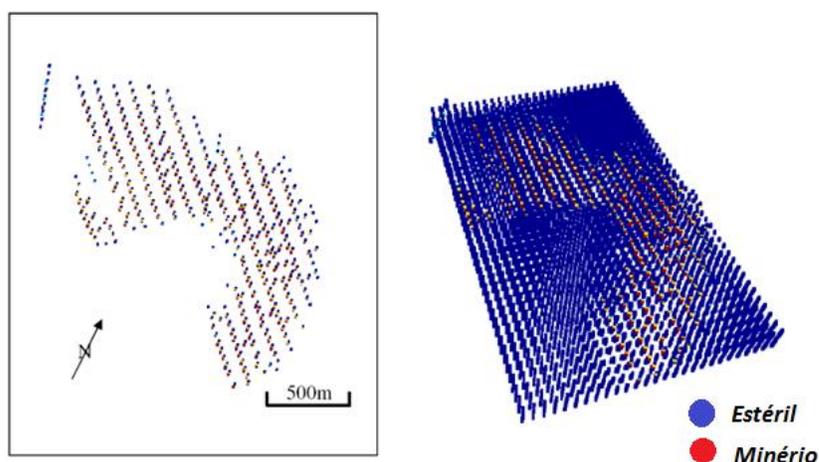


Figura 4.2: distribuição dos furos de sondagem originais (esquerda) e integrados aos furos “fantasmas” (direita). Fonte: Osterholt (2006).

Pasti (2012) adicionou aos dados originais as informações provenientes de algumas seções verticais interpretadas. Entretanto, antes de adicioná-las removeu as áreas de prováveis contatos entre o minério e o estéril, que são as zonas de maiores incertezas na modelagem

geológica (Figura 4.3). Assim como na situação anterior, a adição de dados interpretados considerados como verdadeiros levou a resultados que foram visualmente satisfatórios.

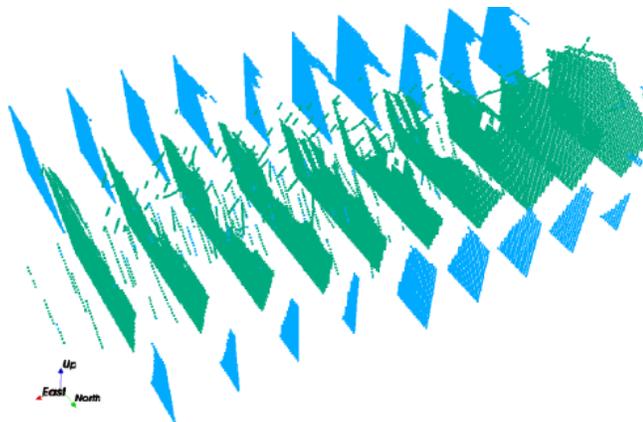


Figura 4.3: seções verticais e furos de sondagens utilizados como dados originais na simulação; em verde, minério e azul, estéril. Note as áreas vazadas entre os litotipos deixadas propositalmente sem definição da geologia. Fonte: Pasti (2012).

A inadequação de tais procedimentos, é que as informações geológicas, baseadas em interpretações subjetivas, são adicionadas diretamente aos dados originais como verdadeiras. Uma interpretação incorreta pode gerar resultados discrepantes, pois as simulações serão produtos dos dados fornecidos. Nessa dissertação, será testada e avaliada uma metodologia capaz de integrar essas informações geológicas como dados secundários, ou seja, como “verdades” relativas, e não absolutas.

Outro desafio na aplicação do algoritmo *SNESIM* em depósitos de ferro é que, em alguns casos, esses depósitos apresentam, ao longo de sua extensão, regiões geologicamente distintas com características irregulares e heterogêneas. Geralmente, essa complexidade geológica do depósito é resultado da combinação de processos tectônicos e diagênicos pós-deposicionais, tais como, dobras, falhas, cisalhamentos ou litificação. Essas discontinuidades podem gerar depósitos com padrões espaciais não estacionários. O algoritmo *SNESIM* não consegue capturar e reproduzir os padrões de não estacionaridade da imagem de treinamento que são armazenadas em uma única árvore de busca.

No processo de varredura da imagem de treinamento, vários moldes de mesma dimensão e de diferentes probabilidades são armazenados na árvore de busca. A partir dessas informações armazenadas, é construída a função de probabilidades cumulativa, que consiste em um conjunto de moldes de múltiplos pontos unidos e distribuídos de acordo com sua probabilidade em dada função. A união desses moldes de mesma probabilidade, em um único ponto do histograma de múltiplos pontos (Figura 2.2), não leva em consideração a informação espacial de cada molde. Portanto, esse processo de construção da função de probabilidades cumulativa é indiferente ao geoposicionamento desses moldes na imagem de treinamento. A consequência é que os padrões de não estacionaridade anteriormente modelados na imagem de treinamento não serão reproduzidos pelo algoritmo.

Strébelle e Zhang (2004) modelaram uma imagem de treinamento não estacionária, onde as elipses foram orientadas no sentido Sul, Oeste, Norte, Leste, na metade do lado esquerdo da imagem, e sentido Norte, Oeste, Sul, Leste, na metade direita. Em seguida, os autores realizaram uma simulação com o algoritmo *SNESIM*. O resultado dessa simulação foi uma mistura entre as orientações das elipses, em ambas as direções, sobre toda a realização correspondente. As características de não estacionaridade modeladas na imagem de treinamento não foram preservadas no modelo produzido pelo algoritmo (Figura 4.4).

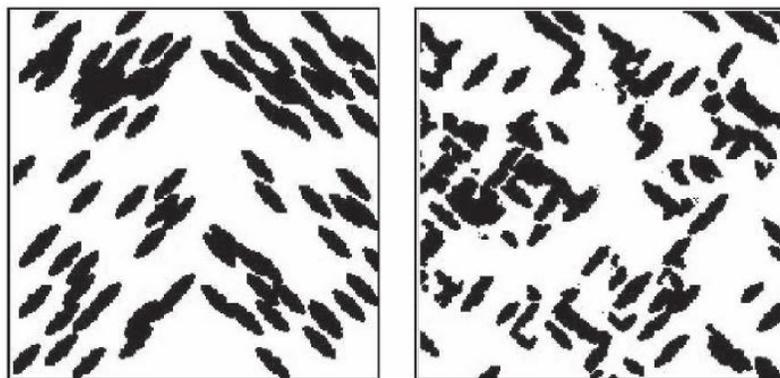


Figura 4.4: imagem de treinamento não estacionária (esquerda) e resultado da simulação por meio do algoritmo *SNESIM* (direita). Fonte: Strébelle e Zhang (2004)

Os autores apresentam uma alternativa para controlar essa limitação. A técnica consiste em: (i) modelar uma imagem de treinamento com padrões espacialmente estacionários; (ii)

construir um modelo que separe as regiões de características estacionárias diferentes; e (iii) aplicar alguns algoritmos capazes de construir para cada região modelada uma função de probabilidades cumulativa diferente. Deste modo, o algoritmo *SNESIM* consegue reproduzir os padrões de não estacionaridade acessando as informações da função de probabilidades cumulativa correspondente à região informada do depósito.

A Figura 4.5 exemplifica a utilização dessa técnica. Inicialmente, uma imagem de treinamento com padrões de canais espacialmente estacionários foi modelada. Em seguida, foram construídos dois modelos que identificam as regiões diferentes e quantificam as características de rotação e espessura de cada região especificada. A construção dos modelos foi baseada em informações de sísmica e interpretação geológica. A partir dessas informações e das 25 amostras disponíveis, o algoritmo *SNESIM* conseguiu reproduzir computacionalmente o modelo geológico com padrões não estacionários de um delta.

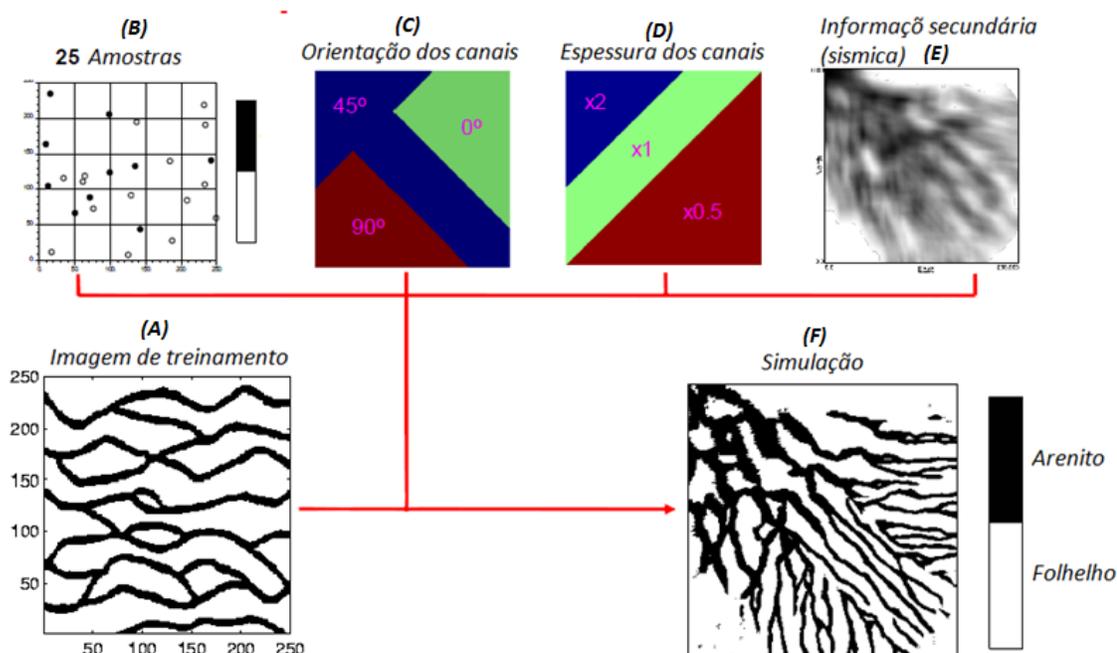


Figura 4.5: exemplo esquemático da utilização de uma técnica de controle de modelos não estacionários. (A) imagem de treinamento; (B) localização dos dados originais; (C) e (D) mapas indicando as regiões com padrões de rotação e espessura diferentes; (E) informações secundárias de sísmica; e (F) resultado da simulação. (modificado de Boucher, 2012).

A desvantagem dessa técnica é que foi desenvolvida para modelagem de reservatório de petróleo, com ambientes sedimentares de extensas camadas que variam somente em relação ao plano x e y. Geralmente, nesse tipo de modelagem, o mergulho das camadas é informado por meio do *grid* estratigráfico em que o modelo de fácies é construído. Portanto, para modelagem de depósitos minerais em 3D com irregularidades e heterogeneidades geológicas nos planos x e z ou y e z, a técnica não se mostrou promissora. Embora, sejam necessárias investigações mais aprofundadas que possam adaptar (ou ajustar) a técnica para as configurações geológicas de depósitos minerais.

Wu *et al.* (2008) propõem outra técnica para integrar as informações de não estacionaridade espacial do depósito no algoritmo de simulação. Os autores sugerem dividir o *grid* de simulação em diferentes regiões e simular cada uma delas com diferentes imagens de treinamento. O resultado são modelos geológicos independentes (Figura 4.6). Apesar de reproduzir as heterogeneidades espaciais dos fenômenos geológicos para cada região especificada em 3D, a técnica apresenta uma desvantagem. Geralmente, a união das diferentes regiões simuladas não se ajusta adequadamente, pois em cada uma delas foram utilizadas imagens de treinamento com padrões desconexos. A consequência dessa limitação são modelos descontínuos em que os padrões transicionais entre as regiões não são reproduzidos. Portanto, o modelo não é considerado “realístico”, mas como uma variedade de imagens com padrões geológicos diferentes em cada zona. Neste sentido, deveriam ser corrigidas as partes do modelo que formam a zona de transição.

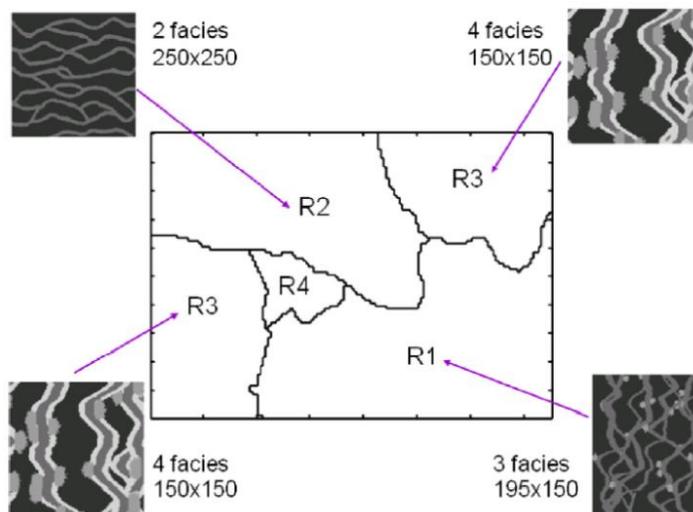


Figura 4.6: simulação com a concepção de regiões: cada região está associada a uma imagem de treinamento específica (preto = fácies de folhelho; cinza escura = canais; cinza = crevasse; cinza clara = diques)

4.2. Metodologia proposta

As técnicas apresentadas na seção anterior adicionaram, ao algoritmo de simulação, informações geológicas baseadas na interpretação, seja por meio de dados artificiais (furos fantasmas e seções verticais) ou pela construção de modelos representativos das regiões heterogêneas do depósito (*grid* separados por regiões). As integrações dessas informações geológicas ocorreram de forma determinística, ou seja, a partir de um pressuposto de “verdade” absoluta. Uma vez que, os dados artificiais foram adicionados aos dados originais ou as simulações foram limitadas a um espaço pré-definido. Uma alternativa para integrar essas informações como “verdade” relativa é proposta nessa dissertação. A técnica sugerida consiste em construir mapas de probabilidades a partir das informações geológicas disponíveis e, em seguida, integrá-los ao algoritmo como dados secundários, probabilísticos, e não com a mesma confiabilidade dos dados originais.

A técnica para adicionar essas informações de modo probabilístico é fundamentada na hipótese de Journel (2000), que por meio da teoria da probabilidade condicional definiu como uma função logística*:

i. A “distância” do evento A ocorrer:

$$a = \frac{1-P(A)}{P(A)} \in [0, +\infty] \quad (4.1)$$

* é uma função sigmóide construída por Pierre François Verhulst em 1845 para representar, por meio de uma curva em forma de **S**, a relação de crescimento populacional durante um tempo. A “distância” é o termo utilizado para localizar a probabilidade de ocorrência como um padrão de comportamento em forma de sigmóide (Gnendenko, 2008).

note que se $P(A) = 1$ então $a = 0$, a distância é zero, portanto a ocorrência do evento A é certa; se $P(A) = 0$ então $a = \infty$, a distância é infinita, logo o evento A não ocorre.

ii. A “distância” do evento A ocorrer dado o evento B:

$$b = \frac{1-P(A|B)}{P(A|B)} \in [0, +\infty] \quad (4.2)$$

iii. A “distância” do evento A ocorrer dado o evento C:

$$c = \frac{1-P(A|C)}{P(A|C)} \in [0, +\infty] \quad (4.3)$$

iv. A “distância” do evento A ocorrer dado os eventos B e C:

$$x = \frac{1-P(A|B,C)}{P(A|B,C)} \in [0, +\infty] \quad (4.4)$$

Segundo a hipótese, a relativa contribuição dos dados do evento C é a mesma, antes e depois de conhecer o evento B, que é definida pela relação:

$$\frac{x}{b} = \frac{c}{a} \quad (4.5)$$

A partir da Equação (4.5), infere-se que a probabilidade do evento A ocorrer dado os eventos B e C é:

$$P(A|B, C) = \frac{1}{1+x} = \frac{a}{a+bc} \in [0,1] \quad (4.6)$$

Para mostrar como essa hipótese é utilizada pelo algoritmo *SNESIM*, considere o exemplo:

i. Dado um banco de dados, a probabilidade de uma determinada categoria ser minério é $P(A) = 50\%$ [$P(A)$ = probabilidade de um evento A ocorrer];

ii. Dada a varredura da imagem de treinamento, a probabilidade dessa categoria ser minério, $P(A)$, uma vez que três categorias vizinhas são minério é $P(A/B) = 80\%$ [$P(A/B)$ = probabilidade de um evento A ocorrer, uma vez que B tenha ocorrido];

iii. Dadas as informações secundárias (sísmica), a probabilidade dessa categoria ser minério, $P(A)$, uma vez que cinco categorias vizinhas são de estéril é $P(A/C) = 55\%$ [$P(A/C)$ = probabilidade de um evento A ocorrer, uma vez que C tenha ocorrido];

Usando as equações (4.1), (4.2) e (4.3) com $a = 1$, $b = 0,25$ e $c = 0,81$, pode-se calcular a probabilidade do evento A (dados originais) ocorrer dado os eventos B (imagem de treinamento) e C (dados secundários). Esta probabilidade é definida pela Equação (4.6), em que $P(A|B, C) = 1 / (1 + 0,25 \times 0,81) = 0,83$, ou seja, a probabilidade de determinada categoria ser minério, uma vez que três categorias vizinhas são minério e cinco são de estéril é de 83%.

O resultado do exemplo mostra como o algoritmo *SNESIM* integra as probabilidades da imagem de treinamento e das informações secundárias nos resultados das simulações. O procedimento executado pelo algoritmo, conforme apresentado, pode ser resumido: (i) inferir da imagem de treinamento a probabilidade condicional $P(A/B)$ dadas as amostras primárias; e (ii) atualizar $P(A/B)$ de acordo com a Equação (4.6), utilizando a probabilidade condicional $P(A/C)$.

Outro recurso disponível no algoritmo *SNESIM*, quando dados secundários são utilizados, é o *tau model* (Journel, 2002). Esta ferramenta computacional hierarquizada, de acordo com o interesse do modelador, as probabilidades condicionais, a partir da equação:

$$\frac{x}{a} = \left(\frac{b}{a}\right)^{\tau_1} \left(\frac{c}{a}\right)^{\tau_2} \quad (4.7)$$

onde, τ_1 e τ_2 são pesos independentes entre si que controlam as probabilidades condicionais da imagem de treinamento (τ_1) e das informações secundárias (τ_2). Os valores desses pesos variam entre 0 e 1, quanto maior o valor, maiores as chances dos eventos condicionados a imagem de treinamento ou informações secundárias ocorrerem. Esses pesos permitem informar para o

algoritmo que as probabilidades locais dos dados secundários têm uma maior chance probabilística de ocorrer. Para isso, basta selecionar um valor de peso maior para os dados secundários em relação ao valor informado para imagem de treinamento. A situação contrária, onde os padrões da imagem de treinamento têm maiores chances de ocorrência, também pode ser ajustada.

Essa possibilidade do algoritmo *SNESIM* integrar dados secundários, como probabilidades condicionais e com pesos de importância diferentes, permite uma via de comunicação poderosa entre o modelador e o algoritmo. Uma vez que, por esse caminho, o modelador pode interagir com o algoritmo, informando indiretamente conhecimentos geológicos sobre a área de interesse.

A metodologia proposta de interação entre o modelador e o algoritmo *SNESIM*, de forma probabilística, para modelagem de depósitos de minério de ferro consiste na aplicação dos seguintes passos, detalhados e exemplificados a seguir (Figura 4.7):

- i. Construção do modelo geológico simplificado e da imagem de treinamento;
- ii. Geração dos mapas de probabilidade por algoritmo de janelas móveis;
- iii. Simulação por (CO) *SNESIM* com informações secundárias; e
- iv. Validações e análises dos resultados.

O passo (i) foi realizado em um programa de modelagem geológica tipo *CAD*; e os passos (ii) e (iii) foram executados por meio do programa de modelagem geoestatística *SGeMS*.

É importante destacar que os passos citados devem ser sustentados pela análise estatística dos dados, pelo conhecimento geológico da área de interesse e pelas técnicas geoestatísticas apresentadas nessa dissertação.

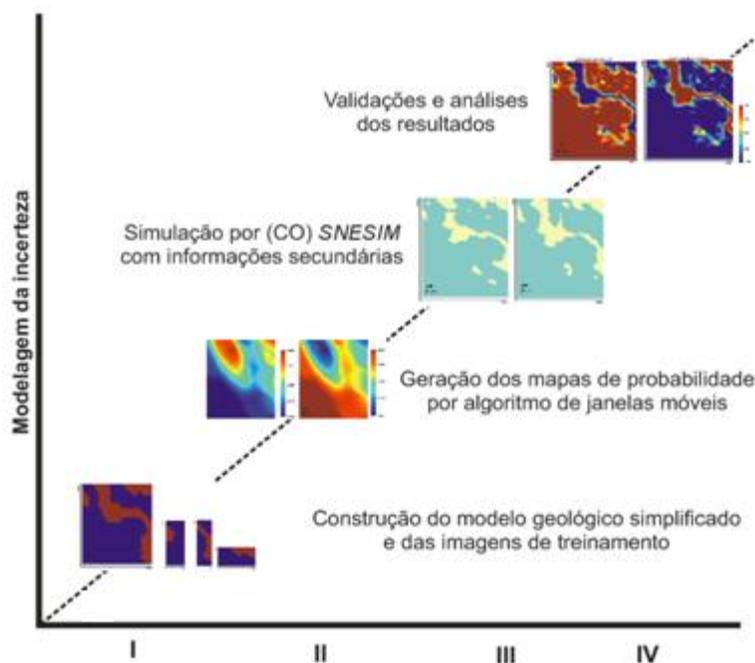


Figura 4.7: resumo esquemático da metodologia proposta representado em forma de um diagrama. No eixo X, as etapas do método, no eixo Y, o nível de quantificação da incerteza sobre o modelo.

4.2.1. Exemplo esquemático

A metodologia proposta será detalhada, por meio de sua aplicação no banco de dados *Walker Lake* modificado, que tem 95 amostras distribuídas em uma região preferencial do depósito em detrimento de outras não amostradas (Figura 4.1). Os parâmetros utilizados e a imagem de treinamento são os mesmos escolhidos no capítulo anterior, exceto o banco de dados, que agora foi reduzido.

Primeiro passo: modelagens

A modelagem geológica de depósitos de ferro complexos é um processo interativo em que diferentes fontes de informações geológicas são integradas. Aspectos estruturais, estratigráficos ou geoquímicos podem ser determinantes para construção desses modelos. Devido essas complexidades inerentes ao processo de modelagem, que em alguns casos, impossibilitam uma modelagem automática via algoritmos de simulação, sugere-se no primeiro passo metodológico,

construir manualmente, através dos métodos de modelagem tradicionais, um modelo simplificado do depósito que inclua as complexidades geológicas interpretadas. A razão desta simplificação do modelo será explicada no passo seguinte. Em seguida, modelar uma ou diferentes imagens de treinamento que reproduzam os padrões geométricos do depósito com características espacialmente estacionárias. A Figura 4.8 mostra um modelo geológico interpretado do banco de dados Walker Lake modificado e três imagens de treinamento com os padrões curvilíneos do depósito (*rever* Seção 3.1). A modelagem foi baseada no conhecimento prévio da distribuição dos padrões do depósito, de acordo com Isaaks e Srivastava (1989).

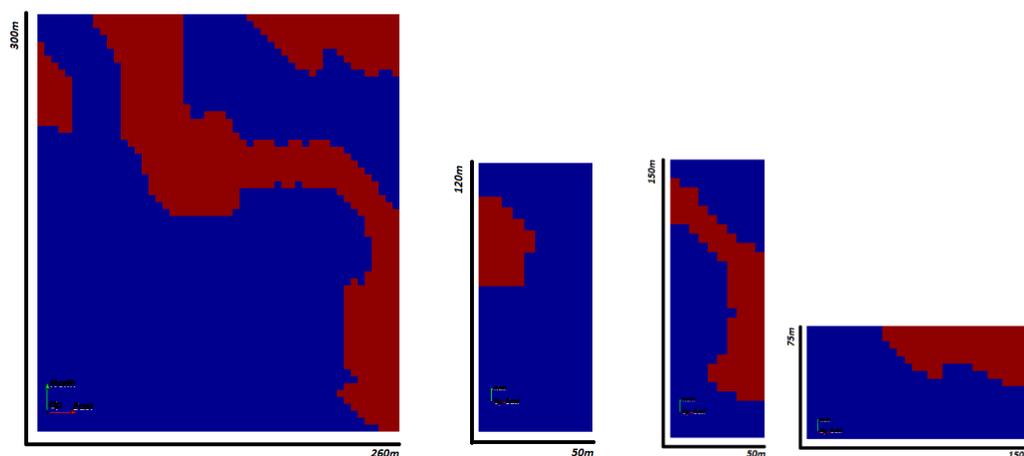


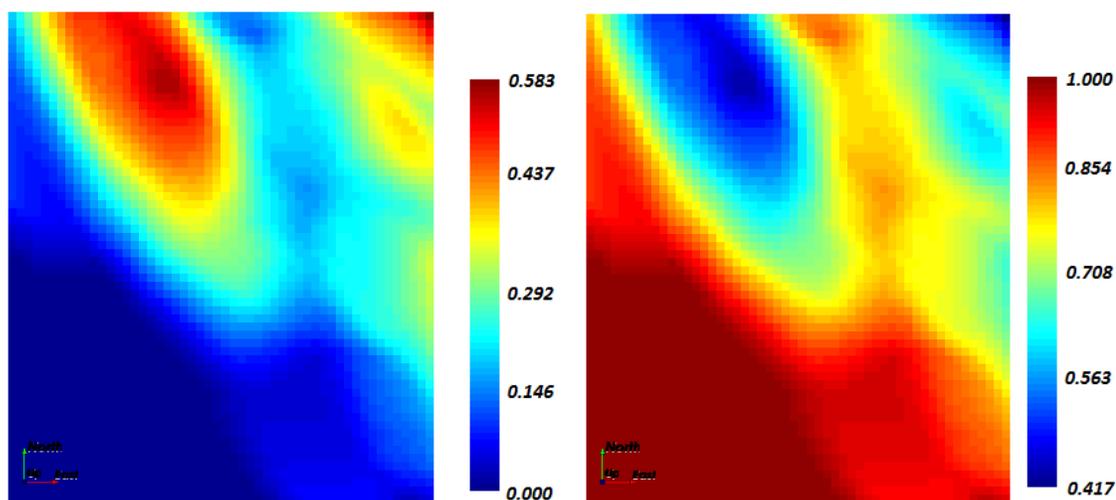
Figura 4.8: modelo geológico interpretado do banco de dados Walker Lake modificado (esquerda) e três imagens de treinamento (direita), respectivamente em sentido horário: ti1, ti2 e ti3. (vermelho = minério e azul = estéril).

Segundo passo: mapas de probabilidade

Depois de construídos o modelo geológico determinístico e as imagens de treinamento com os padrões geométricos do depósito, é aplicado o algoritmo de janelas móveis (*moving windows*) no modelo interpretado. Esse algoritmo calcula o valor da média local de um parâmetro qualquer, por meio dos valores desse parâmetro na vizinhança que estão incluídos em um raio de busca (ou janela) pré-definido. Assim, para cada célula ou bloco é atribuído um valor de probabilidade condicionado aos valores da vizinhança de busca. Quanto maior o raio de busca,

maior é a incerteza associada à interpretação do modelo no bloco específico centrado na célula. O algoritmo de janelas móveis “perturba” o modelo determinístico interpretado e constrói um modelo probabilístico (mapa de probabilidade) para cada categoria ou litotipo do depósito, informando a probabilidade local da categoria ocorrer. Por isso, o modelo geológico construído pode ser simplificado, uma vez que o detalhamento da arquitetura do depósito modelado será extremamente “suavizado”.

A Figura 4.9 mostra os resultados da aplicação do algoritmo de janelas móveis no modelo interpretado do banco de dados Walker Lake modificado. O raio de busca utilizado no algoritmo para esse modelo interpretado foi de 100 m, ou seja, o valor da média local de uma determinada célula será calculado em função dos valores da vizinhança localizados nesse limite de busca. Em termos práticos de modelagem geológica, isso significa afirmar que em um raio de 100 m existe incerteza geológica sobre a interpretação do modelo (ou seja, não há certeza que o litotipo centrado na célula selecionada permanecerá o mesmo em todas as células em um raio de 100 m). Para cada categoria informada, é construído um mapa de probabilidade. A soma das probabilidades de cada litotipo centrado em uma célula (no mesmo ponto) do mapa deve ser igual a 1.



Figuras 4.9: mapa de probabilidade do minério (esquerda) e estéril (direita) construído por algoritmo de janelas móveis, em destaque as escalas com as respectivas probabilidades representadas por diferentes cores.

Terceiro passo: simulações

Os resultados das simulações com algoritmo *SNESIM*, conforme apresentado no Capítulo 3, são sensíveis aos parâmetros do arquivo de entrada selecionados. Neste sentido, a decisão sobre os parâmetros utilizados na simulação devem ser baseados em uma análise de sensibilidade prévia, onde cada efeito deve ser avaliado. Depois de realizada essa análise, a imagem de treinamento (ou imagens) e os parâmetros avaliados são escolhidos de acordo com as interpretações do modelador.

A análise de sensibilidade dos resultados do modelo gerado, a partir do banco de dados Walker Lake modificado, incluindo nessa avaliação os testes com as informações secundárias integradas por meio dos mapas de probabilidade (segundo passo), permitiu selecionar a imagem de treinamento que reproduz de maneira satisfatória os padrões e os parâmetros utilizados nas simulações. Essas escolhas são apresentadas detalhadamente no Anexo B. A Figura 4.10 mostra o resultado de duas simulações que integraram as informações geológicas interpretadas (primeiro passo) como um modelo probabilístico (segundo passo), que foi adicionado como informações secundárias (terceiro passo). Visualmente, os resultados foram satisfatórios, pois os padrões de distribuição do depósito, incluindo as extensas regiões não amostradas foram reproduzidos.

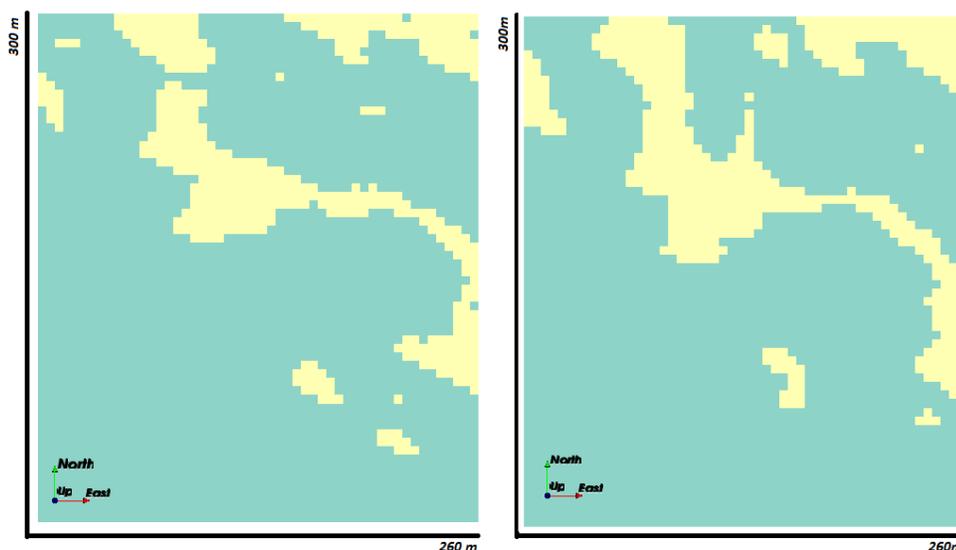


Figura 4.10: duas realizações com *SNESIM* utilizando informações geológicas baseadas na interpretação como dados secundários.

Quarto passo: validações e análise dos resultados

A primeira validação dos resultados é a visual. Características como presença de ruídos no mapa, reprodução dos padrões geométricos curvilíneos, discrepâncias em relação a um modelo de referência interpretado e continuidade geológica dos padrões são avaliados. Outra alternativa de validação, quando disponível, é analisar os resultados comparando-os às informações geológicas de campo, tais como, fotografias, afloramentos, trincheiras ou novos furos de sondagem. Quando essas informações não são disponíveis, sugere-se excluir do banco de dados inicial alguns furos de sondagem e utilizá-los, posteriormente, em uma comparação entre o resultado simulado e a categoria informada no furo excluído para mesma localização correspondente. A Figura 4.11 apresenta os mapas de probabilidades das categorias simuladas; como esperado, as áreas de maiores incertezas são nos prováveis contatos entre minério e estéril.

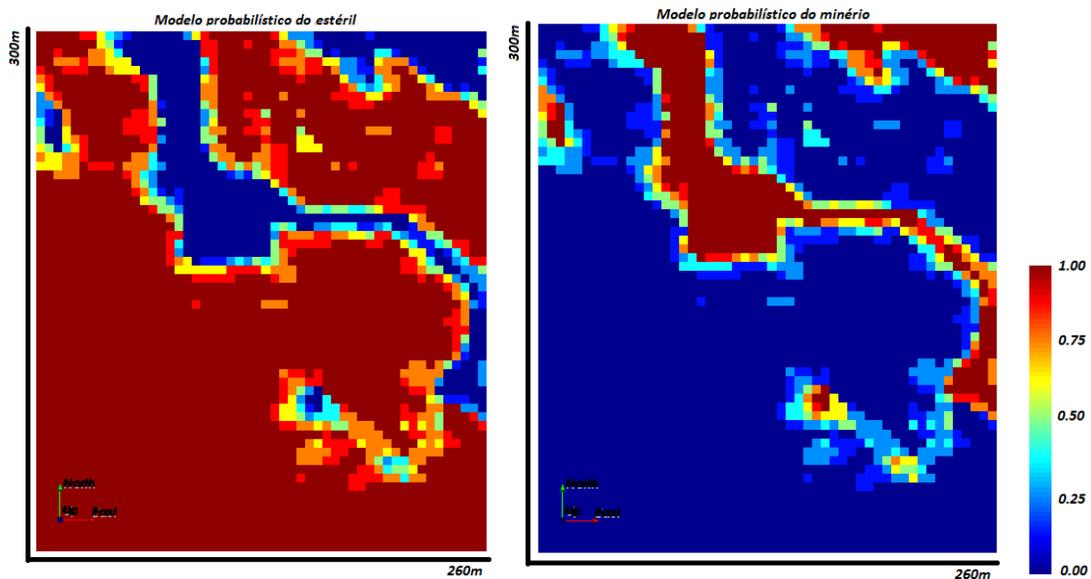


Figura 4.11: modelo de incerteza geológica da categoria estéril (esquerda) e minério (direita) com a respectiva escala de probabilidade.

Capítulo 5

Aplicação da metodologia: estudo de caso em 3D

Neste capítulo, são apresentados os resultados experimentais obtidos no desenvolvimento desta dissertação por meio da metodologia proposta no capítulo anterior. A seção 5.1 investiga os principais aspectos geológicos regionais e locais do depósito de minério de ferro analisado. A seção 5.2 descreve os dados geológicos disponíveis que serão utilizados na simulação. A seção 5.3 aplica no depósito de ferro estudado as etapas metodológicas propostas. A seção 5.4 classifica os recursos de acordo com a incerteza associada. A seção 5.5 discute e avalia os resultados.

5.1. Aspectos geológicos

Quadrilátero Ferrífero

O Quadrilátero Ferrífero (QF), um dos mais importantes distritos mineiros de minério de ferro do mundo, está localizado na borda sul do Cráton do São Francisco, no estado de Minas Gerais, Brasil (Almeida, 1977). As principais unidades litoestratigráficas do QF são: (i) complexos metamórficos granito-gnáissicos diferenciados do Arqueano (embasamento); (ii) as seqüências supracrustais vulcano-sedimentares do Arqueano (Supergrupo Rio das Velhas); (iii) as seqüências metassedimentares paleo-proterozóicas (Supergrupo Minas); e (iv) as rochas intrusivas (Supergrupo Espinhaço) (Figura 5.1).

O Supergrupo Minas inclui quatro Grupos (Dorr, 1969), divididos da base para o topo: (i) Caraça formado por metassedimentos detríticos com idade de 2,65 Ga (Carneiro, 1995); (ii) Itabira constituído por itabiritos, dolomitos e, subordinadamente, metapelitos com idade de 2,52 e 2,42 Ga (Babinski *et al.*, 1995), onde está localizada a seqüência de Formações Ferríferas Bandadas (FFB) com corpos de minério de alto teor lavráveis; (iii) Piracicaba composto por sedimentos clásticos e alguns horizontes conglomeráticos com seixos de itabiritos do Grupo

Itabira, indicando período de perturbação da bacia e de exposição da FFB; e (iv) Sabará formado por metaconglomerados, xistos e filitos, com idade de 2,1 Ga (Carneiro, 1995) (Figura 5.2).

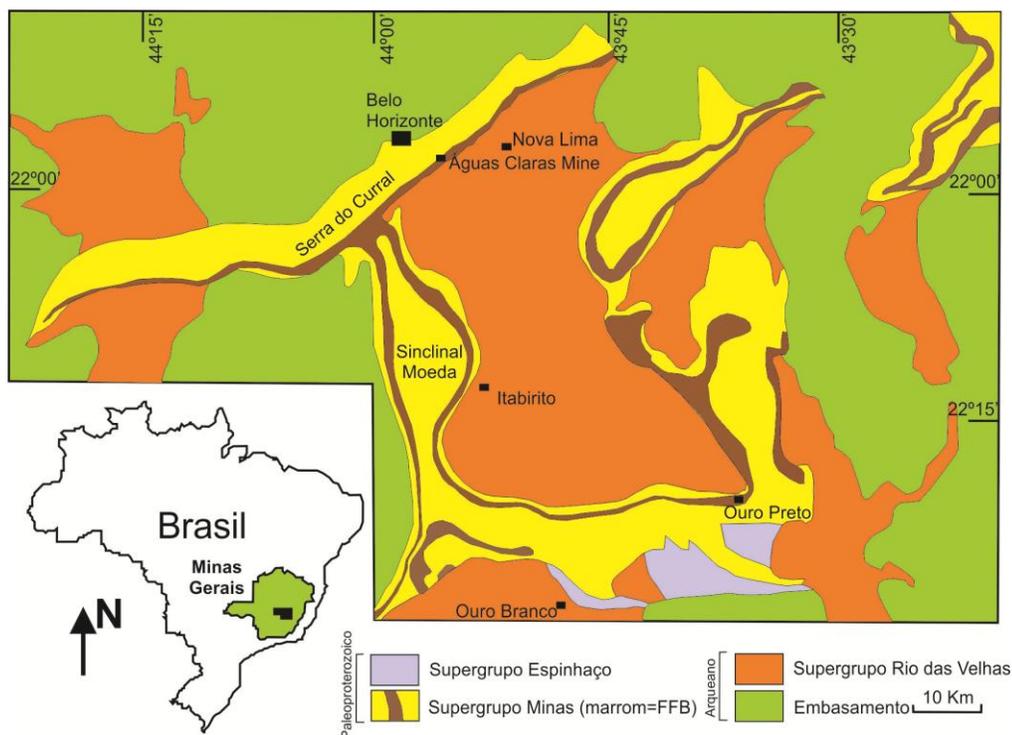


Figura 5.1: mapa de localização e geológico da região do Quadrilátero Ferrífero (modificado de Alkmin e Marshak, 1998).

O Grupo Itabira é dividido em uma unidade inferior, a Formação Cauê onde predominam itabiritos e uma Formação superior, a Formação Gandarela com rochas carbonáticas (dolomitos e mármores dolomíticos e calcíticos), filitos e FFB. Na Formação Cauê, ocorrem as FFB mais espessas do Supergrupo Minas (200 – 300m), que são constituídas por itabiritos, hematititos filitos e, subordinadamente, filitos piritosos. Itabiritos são formações ferríferas metamórficas e fortemente oxidadas que apresentam descontinuamente corpos de minério de alto teor (>64% Fe), de morfologia mais ou menos lenticular e dimensões variáveis desde alguns decímetros até centenas de metros (Eschwege, 1833).

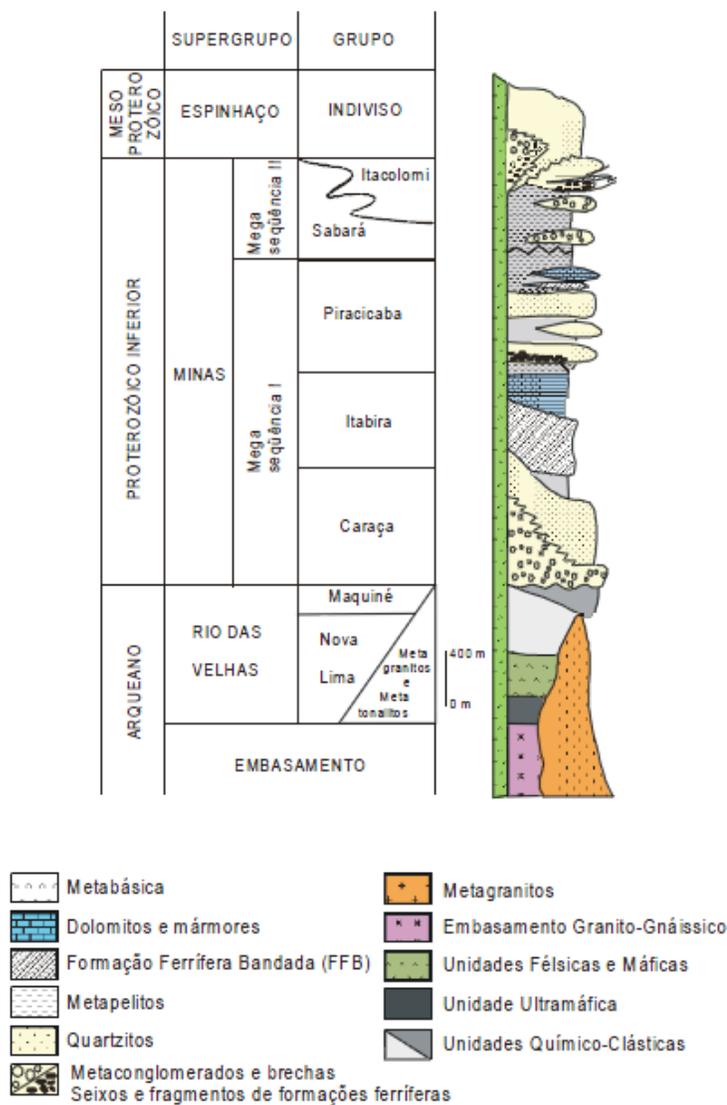


Figura 5.2: coluna estratigráfica do Quadrilátero Ferrífero (modificada de Chemale Jr. *et al.*, 1994).

O depósito de minério de ferro usado no estudo de caso situa-se na porção central do QF, localizado aproximadamente a 40 km da cidade de Belo Horizonte, incluído na parte do flanco sudeste do sinclinal Moeda (Figura 5.1). Apresenta unidades litoestratigráficas do Supergrupo Minas pertencentes à Formação Moeda e Batatal, do grupo Caraça, e à Formação Cauê do Grupo Itabira. O Grupo Caraça, situado na porção sudeste do depósito, é representado por quartzitos de granulação variada (Formação Moeda), sobrepostos por filitos sericíticos de coloração cinza clara, e filitos alterados amarelos, de provável composição carbonática (Formação Batatal). O

Grupo Itabira é representado principalmente por FFB (Formação Cauê), na base, e dolomitos (Formação Gandarela), no topo. A Formação Cauê compõe-se de FFB, fácies óxido, do tipo QF, metamorfizada em baixo grau (Ribeiro, 2003) (Figura 5.3).

Complexidade geológica

A distribuição das tipologias de minério no depósito está condicionada por quatro fatores: (i) a distribuição dos sedimentos originais na bacia, que em virtude da influência de processos secundários (metamorfismo, alteração hidrotermal, deformação etc.) é de difícil avaliação; (ii) a estruturação tectônica, o contraste no comportamento tectônico das formações ferríferas em relação aos metasedimentos sobre e subjacentes (Grupo Caraça e Grupo Piracicaba, respectivamente) resultou em uma complexa estruturação interna nas formações ferríferas com superposição de dobras, desenvolvimento de zonas de cisalhamento e falhas que modificaram diversas características sedimentares e diagenéticas do depósito; (iii) o metamorfismo, os efeitos deste processo nas FFB resultou em transformações mineralógicas que são notáveis nas fácies quimicamente mais alteradas; e (iv) os processos hidrotermais, a presença de fluidos hidrotermais provocou grandes modificações na composição original, de forma que as características primárias foram parcial ou totalmente modificadas (Rosière e Chemale Jr., 2000).

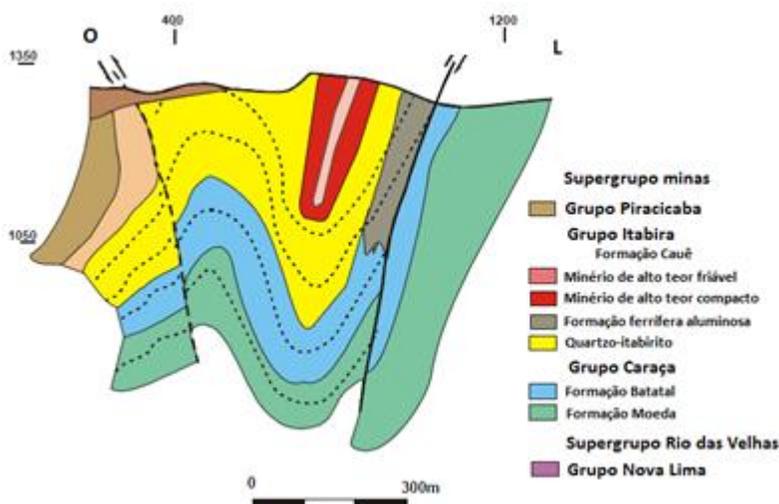


Figura 5.3: seção vertical esquemática do depósito de ferro estudado com direções Leste-Oeste, em destaque, as principais características estruturais e litoestratigráficas (modificado de MBR, 2005).

Tipologias de minérios

Os principais minérios de alto teor que ocorrem no depósito são o itabirito e hematitito (Figura 5.4), que podem apresentar tipos composicionais de: (i) quartzo itabirito, que representa o tipo mais comum encontrado no depósito, correspondente a jaspilitos metamórficos que apresentam alternância de níveis claros (quartzo) e escuros (óxidos de ferro); (ii) itabirito dolomítico constituído de bandas de quartzo, óxidos de ferro, podendo apresentar calcita, clorita e anfibólios; (iii) itabirito anfibolítico constituído de anfibólios de composições variadas que estão orientados segundo o bandamento da camada; e (iv) hematitito que está associado ao enriquecimento residual resultante do processo de intemperismo por meio da ação da água subterrânea que percolou o itabirito por meio de falhas, fraturas e poros, lixiviando os minerais de ganga (Spier *et al.*, 2003).

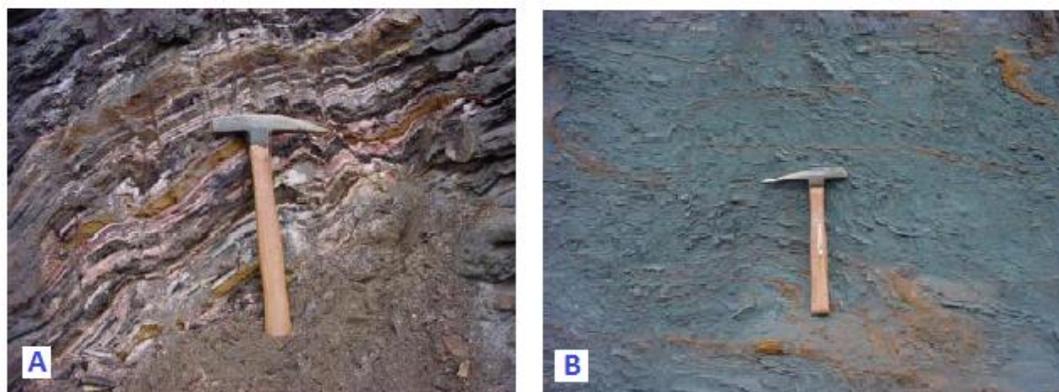


Figura 5.4: principais tipologias do depósito de minério de ferro da Formação Cauê do Grupo Itabira, quartzo itabirito (A) e hematitito friável (B) (modificado de MBR, 2005).

5.2. Dados disponíveis

As campanhas de amostragem do depósito de ferro analisado ocorreram em três estágios: (i) geral ou exploratório, com furos de sondagem em malha semi-regular de espaçamento de 400 m x 400 m ou 400 m x 200 m, distribuídos preferencialmente na direção da Formação Ferrífera (Formação Cauê); (ii) de planejamento de longo-prazo, com malha de espaçamento de 200 m x

100 m para os minérios friáveis de itabirito e de 100 m x 100 m para os corpos de alto teor de hematítico; e (iii) de planejamento de médio prazo, com furos alocados de 70 m x 70 m ou 50 m x 50 m nas prováveis bordas de minério.

Os objetivos principais das campanhas de sondagem foram: (i) no primeiro estágio, reconhecer a geologia regional, por meio da definição dos contatos padrões entre as unidades geológicas não mineralizadas (Formação Batatal, Formação Gandarela, Depósitos Cenozóicos, etc.); (ii) na segunda fase, fornecer suporte geológico para o estudo de viabilidade econômica do depósito; e (iii) no terceiro momento, reduzir a incerteza do modelo geológico, que é uma demanda para o planejamento de curto prazo.

Banco de dados

O banco de dados, fornecido pela empresa mineradora do depósito, contém 2159 amostras com descrição tipológica (mais de 30 tipos) e análise química de três frações granulométricas distintas, que foram descritas e coletadas a partir de 197 furos de sondagem realizados durante os estágios de pesquisa mineral no período de 1975 e 2004.

Nessa dissertação, as análises químicas não foram investigadas (variáveis contínuas) e as tipologias foram divididas em três categorias: hematítico, itabirito e estéril. Além disso, foram retirados do banco de dados os furos de sondagem correspondentes ao estágio de planejamento de médio prazo (espaçamento de 70m x 70m e 50 m x 50 m). Os propósitos desta decisão foram investigar a aplicação da técnica de modelagem geológica com geoestatística de múltiplos pontos durante a fase de exploração e planejamento de longo prazo em comparação a modelagem tradicional; e validar localmente os resultados gerados pela simulação em relação aos dados fornecidos pelos furos de sondagem excluídos. Neste sentido, do total de 197 furos originais foram removidos 84 furos (42,6%), restando 113 furos (57,4%), distribuídos em um espaçamento regular na direção Leste-Oeste de 100 m, que foram utilizados na simulação como dados primários (*hard data*) e apresentam uma frequência relativa de 23,5% de hematítico, de 70% de itabirito e 6,5% de estéril (Figura 5.5).

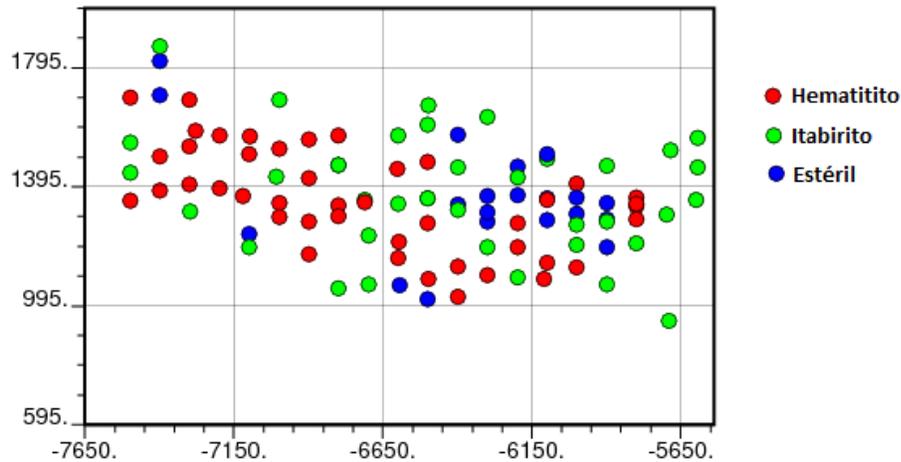


Figura 5.5: mapa de localização dos furos de sondagem utilizados nas simulações (*hard data*) em seção paralela ao plano horizontal.

Seções verticais

A partir das descrições dos furos originais, o especialista da empresa responsável pelo depósito, construiu 40 seções verticais interpretadas em programa de modelagem tipo *CAD*. Estas seções interpretadas, fornecidas para esse trabalho, estão distribuídas a cada 50 m entre as posições -5550 m e -7500 m ao longo da direção Leste-Oeste e são representadas por linhas que delimitam as tipologias presentes no depósito. Destas 40 seções disponíveis, foram utilizadas somente dez (25%), que foram simplificadas para três domínios geológicos diferentes, hematítico, itabirito e estéril (Figura 5.6). O objetivo de utilizar estas dez seções foi criar a partir delas um modelo simplificado da geologia do depósito para, em seguida, construir os mapas de probabilidades que serão empregados como informações secundárias, conforme a metodologia proposta no capítulo anterior.

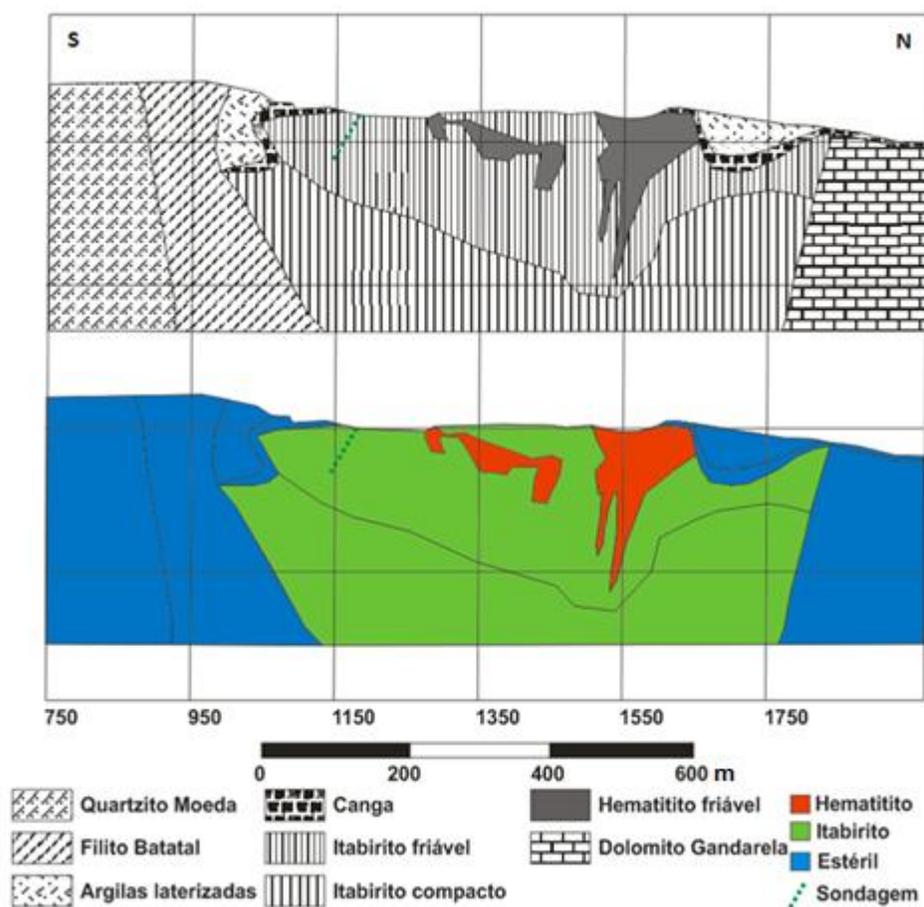


Figura 5.6: seção transversal interpretada da geologia do depósito, parte superior, e simplificada, na parte inferior.

Modelo de referência

Outro conjunto de dados fornecido pela empresa foi o modelo de blocos do ano de 2005, que contém o modelo geológico do depósito e as estimativas de teores em um total de aproximadamente 695 mil blocos de dimensões 10x10x10 metros, com frequência relativa de 3,8% de hematítico, 58% de itabirito e 38,2% de estéril. Este modelo foi referendado por auditores externos e utilizado pela mineradora para o planejamento de lavra e avaliação de recursos e reservas minerais. Nesse trabalho, este modelo geológico de referência, construído de forma tradicional, será comparado com os resultados das simulações com propósito de avaliar as principais semelhanças e diferenças entre eles.

5.3. Aplicação da metodologia proposta

5.3.1. Modelo geológico simplificado

A construção do modelo geológico simplificado foi baseada nas dez seções verticais interpretadas do depósito, que estavam espaçadas a cada 200 m na direção Leste-Oeste. A partir dessas seções foi realizada uma interpolação por triangulação entre elas em um programa de modelagem geológica. O resultado deste procedimento de união foi um sólido geológico (*wireframe*) representativo do domínio de rochas de hematitito (Figura 5.7, A). As formas geométricas modeladas de itabirito também foram interpoladas por triangulação, que resultaram em um sólido geológico correspondente ao domínio de rochas de itabirito (Figura 5.7, B). O estéril não foi modelado, sendo representado no modelo pelo volume não preenchido de hematitito ou itabirito e delimitado pela topografia do depósito. Ressalta-se que as 30 seções disponíveis e removidas desse trabalho não foram utilizadas como consulta para as decisões de modelagem. Será avaliado e discutido, se a partir de um número menor de furos e seções, é possível construir um modelo geológico consistente (modelo de referência) com menos trabalho operacional e menor tempo

A união entre estes domínios de hematitito, itabirito e estéril representam o modelo geológico simplificado do depósito com frequência relativa de 2,5% de hematitito, 59,2% de itabirito e 38,3% de estéril, que foi delimitado nas mesmas dimensões do modelo de referência, incluindo o tamanho de blocos de 10x10x10 metros.

É importante enfatizar que esta simplificação do modelo geológico é feita em função da finalidade do estudo, pois nesse caso o modelo será “suavizado” e transformado em modelos de probabilidades que serão utilizados como informações secundárias na simulação. Neste sentido, a proposta deste modelo simplificado é apenas auxiliar as decisões do algoritmo de simulação de múltiplos pontos (*SNESIM*).

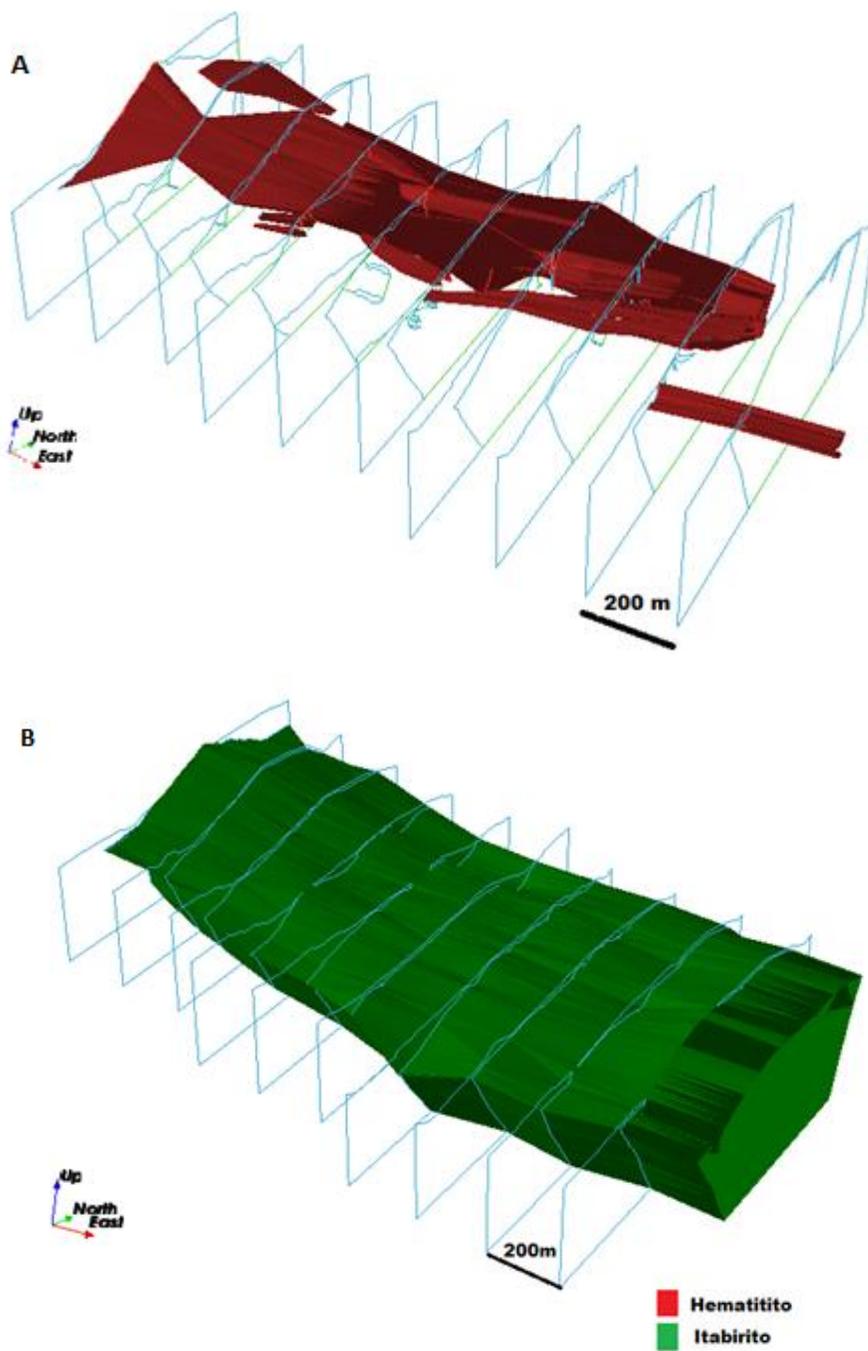


Figura 5.7: sólido geológico (*wireframe*) da tipologia hematitito (A) e itabirito (B).

5.3.2. Imagem de treinamento

A imagem de treinamento foi construída através da extrusão de duas seções geológicas verticais, com espaçamento de 200m entre elas. Entretanto, devido as tipologias presentes nas seções interpretadas estarem orientadas em sentidos diferentes nos lados NS, portanto não-estacionárias, a imagem de treinamento foi baseada somente na metade Norte das seções, afim de que os padrões fossem reproduzidos corretamente (*rever* Seção 4.1). Deste modo, a imagem de treinamento construída possui dimensões de 400m na direção NS, 700m em LO e 420m de profundidade, com um total de 68.674 blocos de tamanho 10x10x10 (m³), com frequência relativa de 4% de Hematitito, 35% de Itabirito e 61% de Estéril (Figura 5.8).

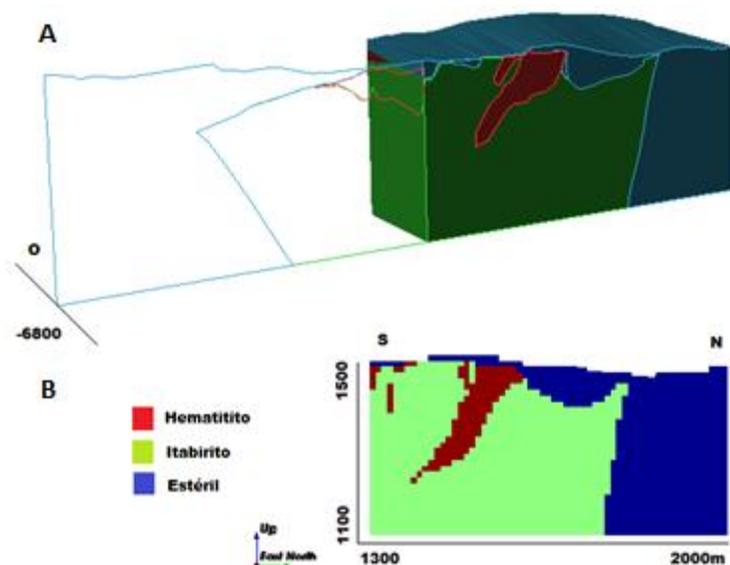


Figura 5.8: extrusão da imagem de treinamento a partir das seções interpretadas (A) e imagem de treinamento utilizada na simulação (B).

5.3.3. Modelos de probabilidades

A partir do modelo geológico simplificado foram criados três novos modelos, um representativo da tipologia hematitito (indicador 1) e não hematitito (indicador 0), outro do itabirito (indicador 1) e não itabirito (indicador 0) e o último do estéril (indicador 1) e não-estéril (indicador 0). O objetivo foi aplicar em cada um desses modelos binários o algoritmo de Janelas Móveis para construção de modelos de probabilidade. No algoritmo de Janelas Móveis foi

utilizado um raio de busca anisotrópico de 80 m na direção vertical, 100 m no sentido Leste-Oeste e 100 m no eixo Norte-Sul. A escolha das dimensões e direções dos raios de busca aplicados no algoritmo foi decidida a partir de análise de sensibilidade dos modelos gerados.

Os resultados foram três modelos de probabilidade, um para cada tipologia que variam entre 0% a 100% de chance de ocorrência. Repare na suavização nos contatos geológicos e nas regiões de maior incerteza, que para os mapas de hematitito estão concentrados na parte central superior do depósito e para o itabirito ou estéril nas partes laterais (Figura 5.9).

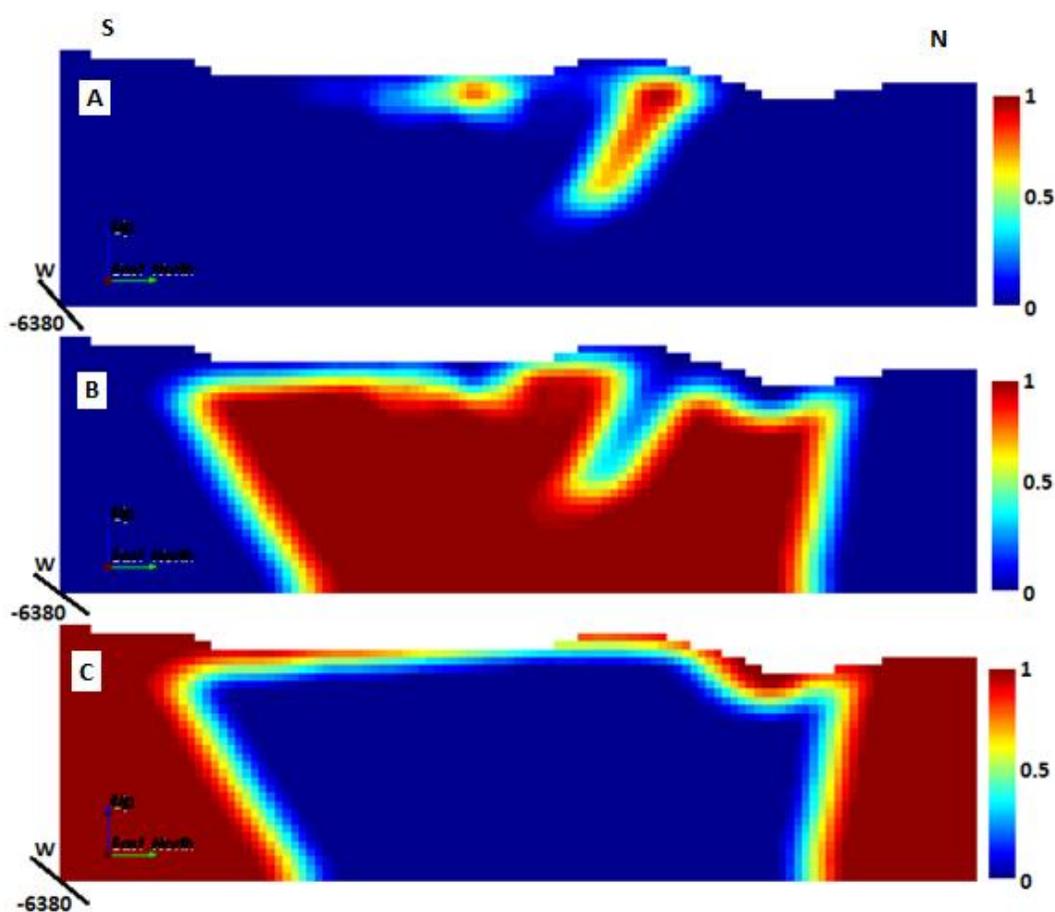


Figura 5.9: seções transversais dos modelos de probabilidade das categorias hematitito (A), itabirito (B) e estéril (C).

5.3.4. Simulação dos litotipos

Para cada tipologia de minério, foi realizada 100 simulações, em um computador de 20 GB de RAM e processador com 8 núcleos (Intel Core i7 com 3.90 GHz) com sistema operacional *Windows 7* (64 bits). O tempo para cada realização foi de aproximadamente 3,5 minutos.

Os parâmetros do algoritmo *SNESIM* foram selecionados a partir da análise de sensibilidade dos resultados gerados. A proporção marginal do modelo simplificado foi de 2,5% para o hematitito, 50,2% itabirito e 38,3% estéril; a geometria do molde foi isotrópica de 50 m com três múltiplos moldes; o *Tau Model* foi de 1 para as informações secundárias e a imagem de treinamento; e o fator de ajuste foi de 0.5 (*ver Anexo C*).

Os resultados das simulações foram visualmente satisfatórios. Em termos gerais, as tipologias foram reproduzidas de forma realística (Figura 5.10):

- i. O hematitito ficou concentrado na região superior do depósito, não atingindo o limite de base;
- ii. o formato curvilíneo e lentiforme dos corpos de hematitito foram reproduzidos na direção Norte-Sul;
- iii. o hematitito e o itabirito estão concentrados ao longo da direção Leste-Oeste, não ocorrendo nas áreas laterais do depósito;
- iv. a incerteza sobre os limites das bordas laterais do corpo de itabirito foi reproduzida nos modelos simulados;
- v. não ocorreram ruídos significativos (blocos de minério dispersos) nos resultados; e
- vi. o padrão de não estacionaridade foi reproduzido, mesmo utilizando uma imagem de treinamento estacionária, portanto o algoritmo conseguiu capturar e processar as informações secundárias de não estacionaridade;

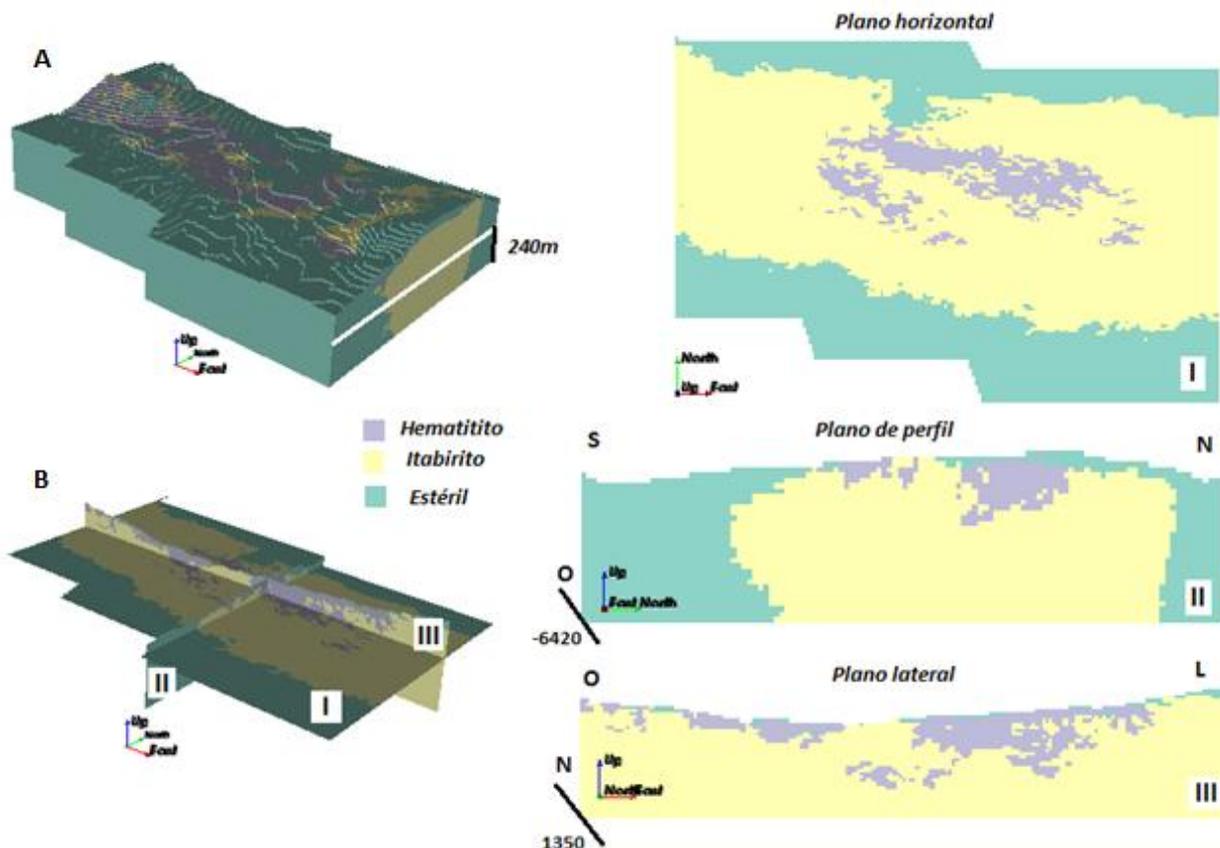


Figura 5.10: resultado da realização 25, onde são mostrados a vista geral do depósito simulado (A) e o depósito seccionado (B) nos planos horizontal (I), de perfil NS (II) e frontal LO (III).

5.3.5. Comparações e validações.

As seções dos modelos simulados e de referência foram comparadas visualmente entre elas (Figura 5.11). O padrão curvilíneo na direção sudoeste do plano horizontal presente no modelo de referência (A.I) foi reproduzido pelo sólido geométrico de itabirite no modelo simulado (B.I). A geometria curvilínea do hematitito do modelo de referência (A.II) foi reproduzida no modelo simulado (B.II), no entanto neste último o hematitito localizado na porção Norte da seção atingiu uma menor profundidade em relação ao primeiro. Além disso, os contatos laterais entre o itabirite e o estéril foram mais conservadores no modelo simulado do que no modelo de referência, que tem um limite lateral interpretado definido. A distribuição do hematitito, que ocorre somente na parte superior do depósito, do modelo de referência (A.III) foi

reproduzida no modelo simulado (B.III). Assim como, a extensão de estéril presente no topo de ambos os modelos

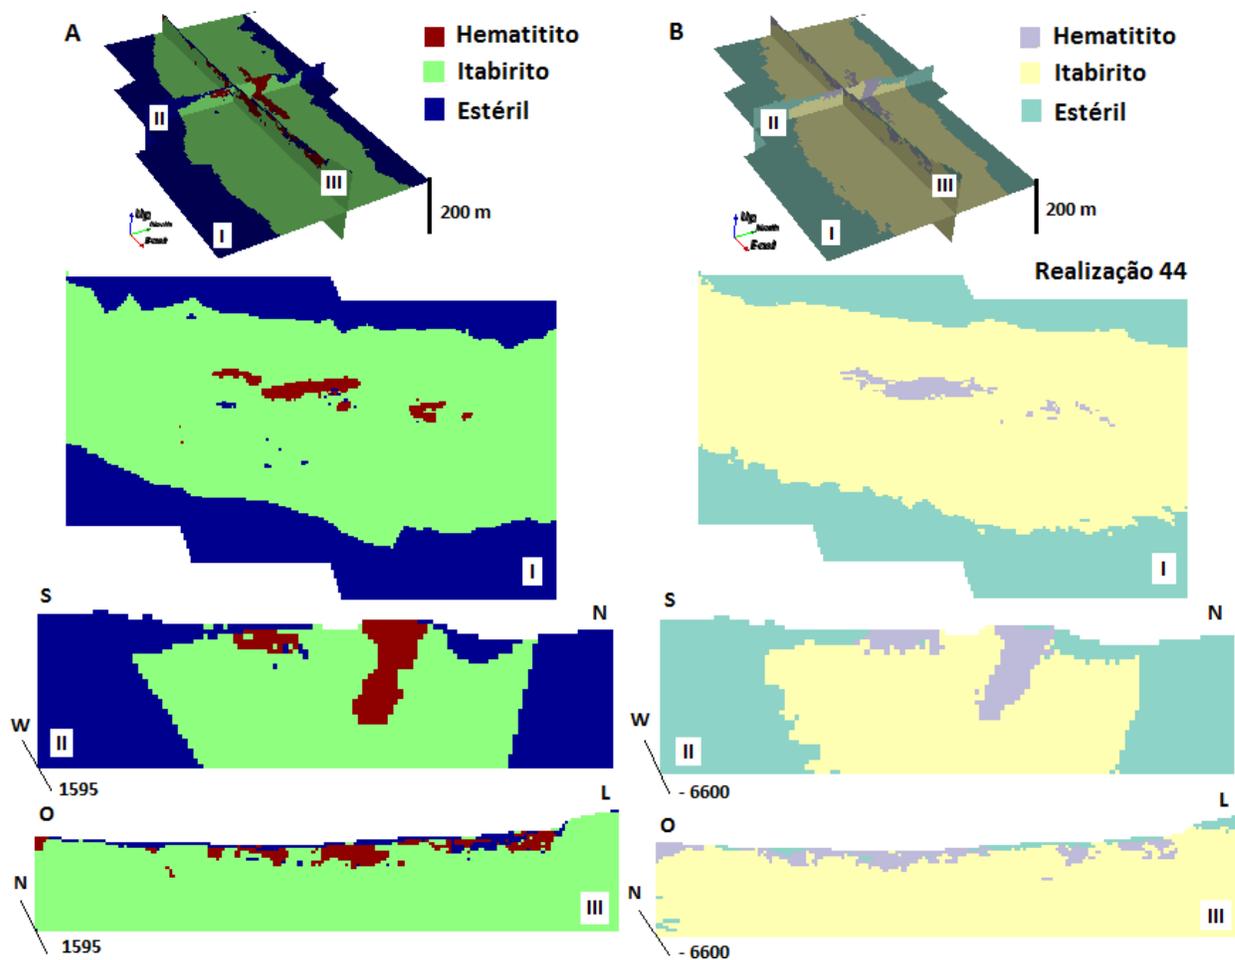


Figura 5.11: comparação entre o modelo de referência (A) e o modelo simulado (B), em destaque as seções nos planos horizontais (I), de perfil na direção NS (II) e lateral na direção LO (III) dos modelos.

As proporções das tipologias de hematitito e itabirito flutuam de forma moderada. O hematitito variou entre os valores de proporção de 3,9 e 4,2%, enquanto o itabirito oscilou entre os valores de 56,2 e 57,3. Na Figura 5.12, estas proporções são mostradas em um gráfico de colunas, incluindo a categoria estéril que variou entre os valores de proporção de 39,2% e 39,5%. Além disso, as proporções do modelo de referência de 3,8% de hematitito, 58% de itabirito e 38,2% de estéril são comparadas com os modelos simulados. Os resultados mostraram que

ocorreu uma diferença significativa nos valores de proporções do itabirito, que foi maior no modelo de referência, e do estéril, maior no modelo simulado.

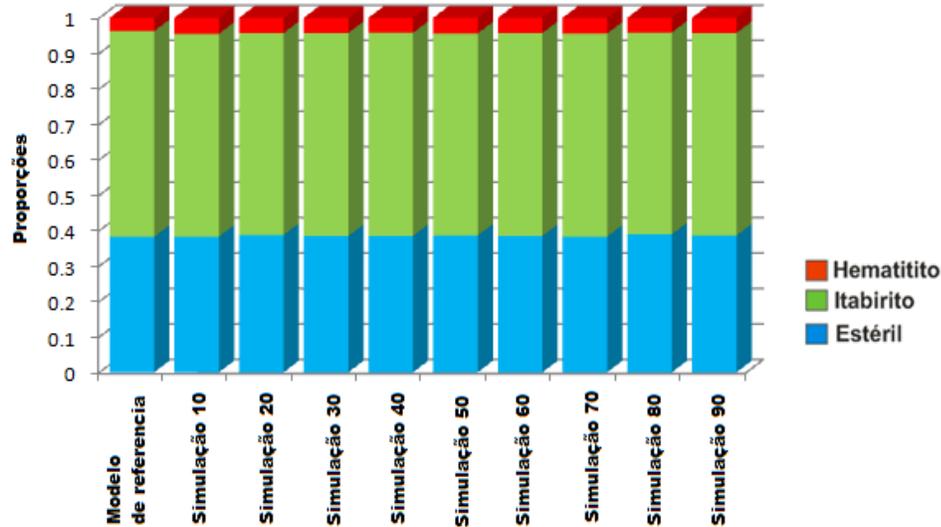


Figura 5.12: proporções dos litotipos por realização em comparação as proporções do modelo de referência.

Os resultados das simulações foram confrontados com os furos de sondagem utilizados na simulação e os removidos do banco de dados. O objetivo é avaliar se as realizações honraram as amostras primárias e quantos se aproximaram das amostras removidas. Na Figura 5.13 são apresentadas duas seções transversais (NS) de diferentes realizações e posições espaciais com furos de sondagens incluídos (A e B). De modo geral, as simulações honraram os furos utilizados de modo que os prováveis contatos entre as tipologias foram reproduzidos consistentemente. Repare que uma grande extensão do depósito foi estimada sem amostras primárias. Para esse caso, o algoritmo acessou os padrões geológicos contidos na imagem de treinamento e nas informações secundárias. Na Figura 5.14 as seções transversais (NS) de diferentes realizações e posições espaciais (A e B) são confrontadas com os furos de sondagens removidos do banco de dados. Embora o algoritmo não tenha acessado as informações contidas nos furos excluídos, tais padrões foram reproduzidos localmente nas realizações, validando que os resultados foram consistentes com o melhor detalhamento amostral.

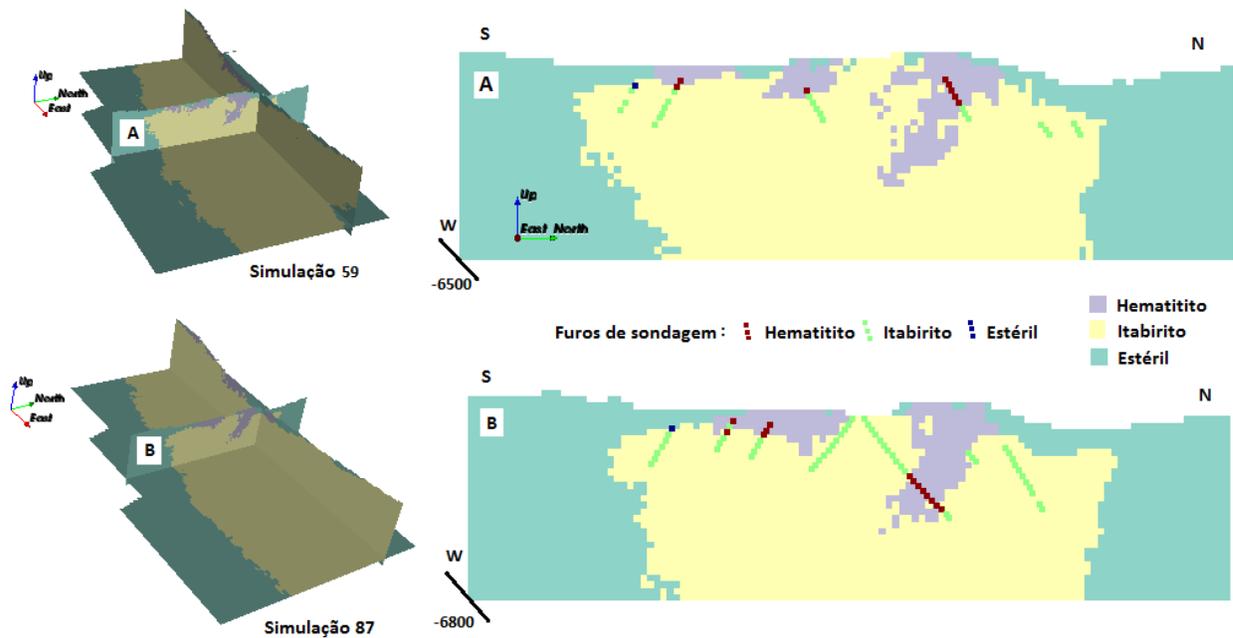


Figura 5.13: seções transversais das simulações 59 (A) e 87 (B) em confronto com os furos de sondagem utilizados como amostras primárias.

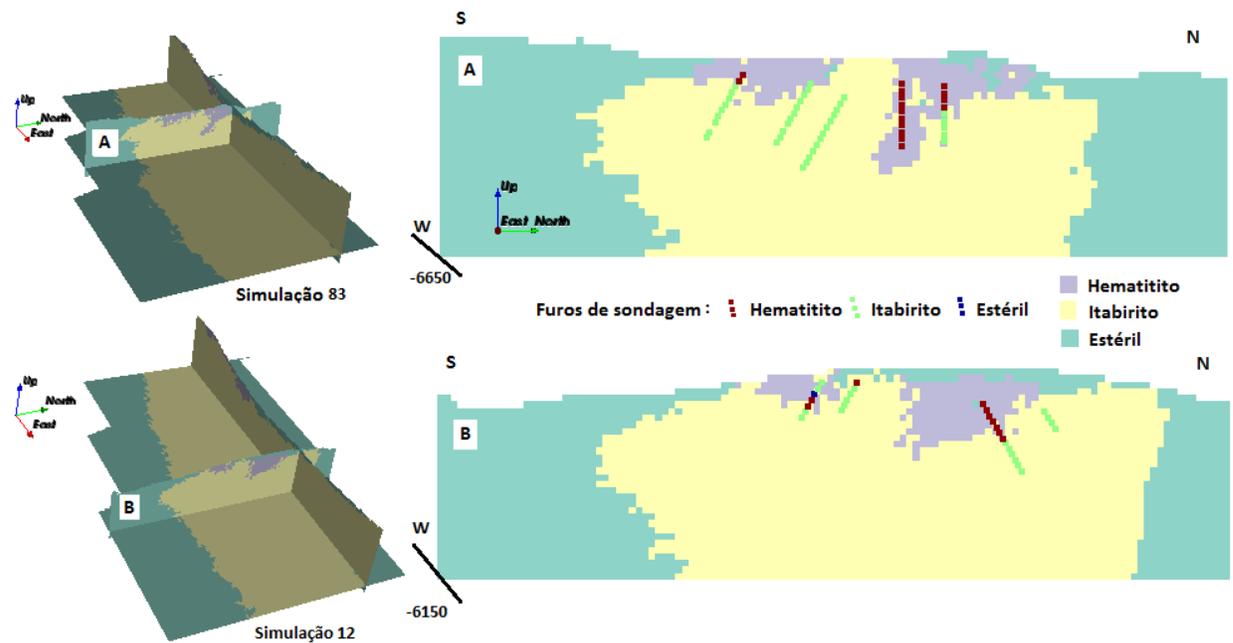


Figura 5.14: seções transversais das simulações 83 (A) e 12 (B) em confronto com os furos de sondagem removidos do banco de dados.

5.4. Quantificação da incerteza

Os resultados da simulação de múltiplos pontos foram apresentados na seção anterior como valores categóricos, ou seja, indicadores. A incerteza sobre as realizações geradas pode ser acessada por meio do cálculo do valor médio, em cada ponto, do conjunto das 100 realizações. Assim, os valores que antes eram absolutos, transformam-se em valores relativos em um intervalo de probabilidade que oscila entre 0 e 1. Este procedimento de compilação das 100 realizações foi realizado para as tipologias investigadas, os resultados foram três modelos de probabilidade, um para cada tipologia. A incerteza no modelo de probabilidade do itabirito é maior, com 24,62% dos blocos dentro do intervalo de distribuição que varia entre 0.01 e 0.99% de probabilidade. Enquanto, 11,07 e 18,17% dos blocos de hematitito e estéril, respectivamente, pertencem a esse mesmo intervalo de incerteza (Figura 5.15).

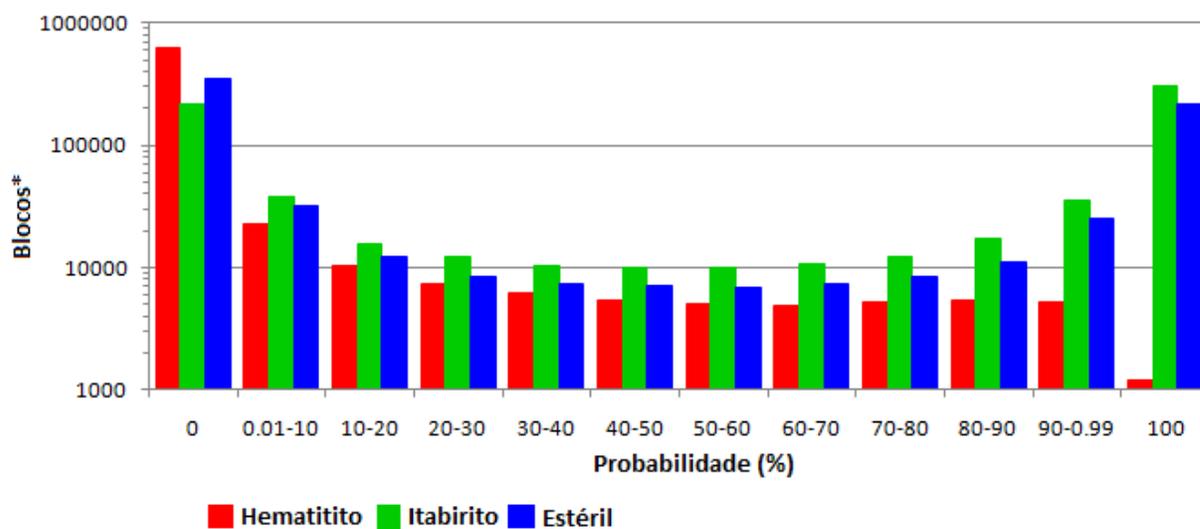


Figura 5.15: distribuição das probabilidades das tipologias de acordo com a incerteza.

O modelo de classificação dos recursos foi construído a partir dos modelos de probabilidades das tipologias. Blocos com valores maiores que 50% de probabilidade foram classificados como pertencentes ao respectivo modelo. Os resultados dessa classificação foram proporcionalmente distribuídos em uma nova escala de probabilidades. Blocos classificados como Estéril foram distribuídos entre 0% e 100/3% de probabilidade; blocos classificados como Itabirito entre 100/3% e 200/3% de probabilidade; e blocos de Hematitito entre 200/3% e 100%.

A Figura 5.16 mostra esse modelo de classificação onde as probabilidades estão representadas por uma escala de cores. Note que blocos pertencentes aos contatos entre os litotipos são os que apresentaram maiores incertezas, como era esperado.

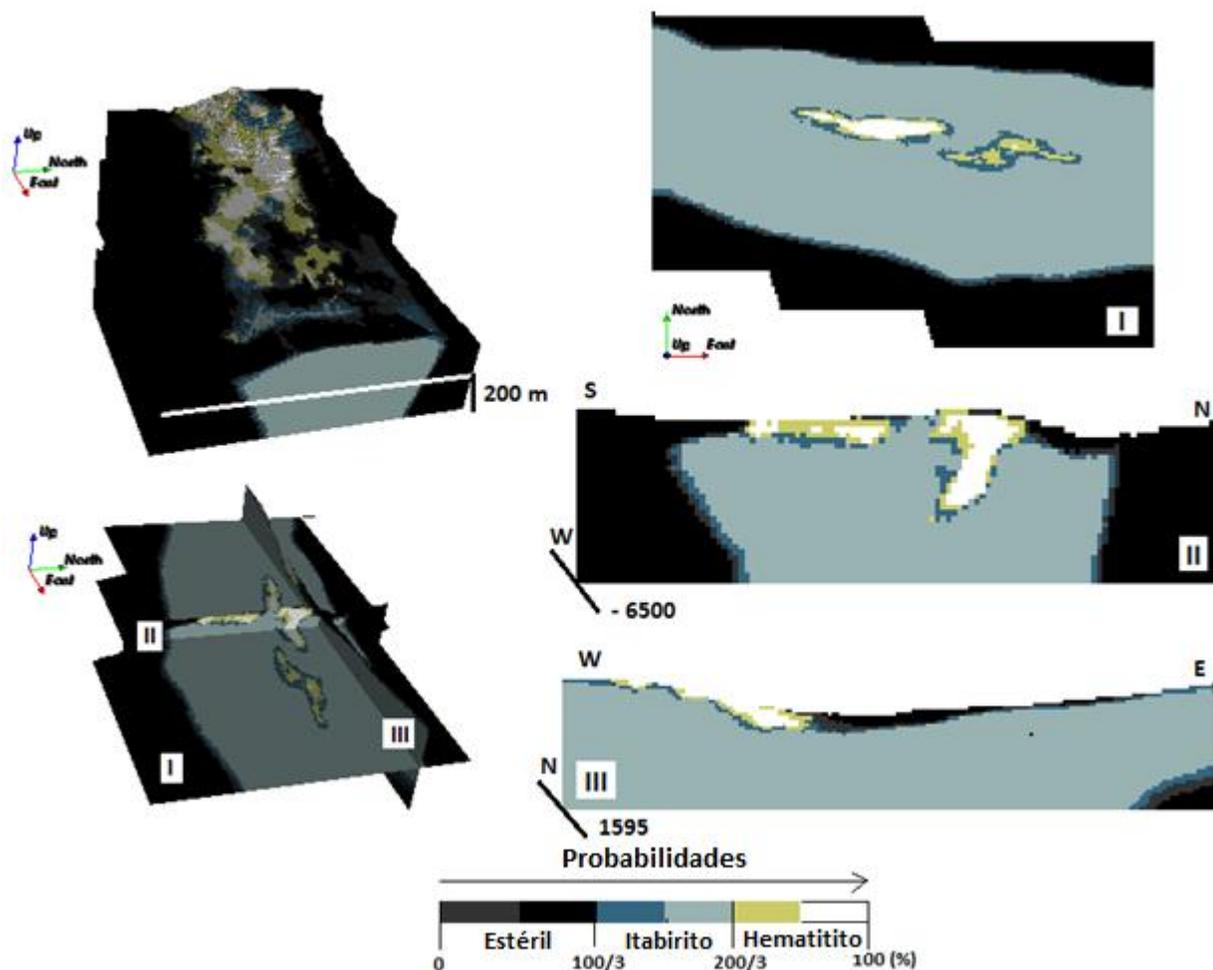


Figura 5.16: modelo de classificação construído a partir dos modelos de probabilidade.

A diferença entre os volumes do modelo de referência e o modelo de classificação com 100% de probabilidade foram comparados. O volume de Hematitito do modelo de referência foi quatro vezes maior do que o volume do modelo classificação. Os volumes de Itabirito e Estéril do modelo de classificação foram 15% menores do que o volume de referência (Figura 5.17).

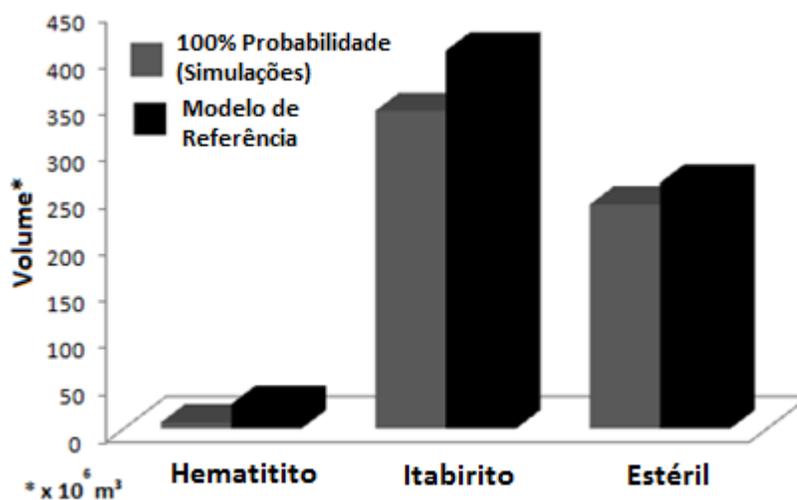


Figura 5.17: comparação entre os volumes do modelo de classificação com 100% de probabilidade e os volumes do modelo de referência.

5.5. Discussões

O algoritmo *SNESIM* conseguiu integrar as informações de geologia regional e local do depósito de minério de ferro investigado. A grande extensão não amostrada correspondentes aos Depósitos Cenozóicos e as Formações Batatal e Gandarela formadas por rochas classificadas como estéril foi reproduzida pelo algoritmo conforme a interpretação geológica da área de estudo. Isto foi possível porque as simulações foram condicionadas as informações secundárias dos modelos de probabilidades. Este procedimento permitiu integrar estas informações de conhecimento geológico ao algoritmo de forma satisfatória e probabilística, e não determinística (Figuras 5.2, 5.3 e 5.6).

A partir dos resultados das simulações constatou-se que, apesar da redução de 42,6% dos furos originais e 75% das seções verticais, o algoritmo reproduziu realizações consistentes com o modelo de referência (Figura 5.11). Estes resultados permitem afirmar que o algoritmo de simulação de múltiplos pontos pode ser utilizado nos estágios iniciais de pesquisa mineral com propósito de construir um modelo geológico de referência para elaboração do estudo de viabilidade econômica do depósito, com menor esforço operacional e de tempo.

O modelo geológico simplificado foi fundamental para informar os aspectos globais de distribuições das tipologias no depósito. Entretanto, as decisões de estimativas locais foram

baseadas nas informações contidas na imagem de treinamento e nos modelos de probabilidade (Figuras 5.10). Embora a imagem de treinamento apresentasse um padrão estacionário de distribuição das geometrias (Figura 5.8), o algoritmo reproduziu o padrão não estacionário do depósito de forma realística capturando esta informação nos dados secundários.

A decisão de utilizar as proporções do modelo simplificado (análogo) como proporção marginal, e não das imagens de treinamento ou dos furos de sondagem como investigado no capítulo 3, possibilitou proporções globais mais consistentes com o modelo interpretado (Figura 5.12).

As realizações honram as amostras locais dos furos de sondagem utilizados. Nos casos em que foram confrontados os furos removidos, na maioria das vezes, as realizações respeitaram as informações contidas nestes furos (Figuras 5. 13 e 5.14). Deste modo, infere-se que os resultados das simulações foram consistentes com a realidade geológica conhecida do depósito.

A compilação das simulações permitiu acessar e quantificar a incerteza sobre a classificação dos blocos de recursos minerais de ferro do depósito investigado (Figura 5.15). O sistema de classificação de recursos reproduziu o padrão de incerteza inerente a modelagem geológica dos litotipos, não determinista, o que possibilita uma avaliação mais realista dos resultados. A incerteza sobre o modelo simulado pode ser reduzida com novos furos de sondagem, que podem ser alocados de acordo com o padrão de incerteza reproduzido nas simulações. Para este caso, onde se busca reduzir a incerteza do modelo geológico, que é uma demanda para o planejamento de curto prazo, é aconselhável integrar os furos, com espaçamento de 50x50 m e de 70x70 m, que foram removidos inicialmente do banco de dados utilizado neste trabalho.

Capítulo 6

Conclusões e recomendações

“Se temer que suspeitem ser sua narrativa inverídica, lembre-se da probabilidade”

Jonh Gay

6.1. Objetivos *versus* resultados

O objetivo geral dessa dissertação foi avaliar a aplicação da geoestatística de múltiplos pontos na simulação de depósitos minerais, a partir dos resultados alcançados nesse trabalho, constatou-se que o método de múltiplos pontos, em especial, o algoritmo *SNESIM* pode ser utilizado com sucesso na simulação da incerteza geológica de depósitos minerais.

No capítulo 2 foram apresentadas, teoricamente, as vantagens dos métodos de geoestatística de múltiplos pontos em comparação aos métodos de estatística de dois pontos, quando aplicados na simulação de variáveis categóricas:

- i. melhor reprodução de padrões geométricos complexos, tais como, geometrias curvilíneas complexas de canais fluviais, dobras, falhas, fraturas, estruturas sedimentares ou corpos magmáticos irregulares;
- ii. melhor medida de incerteza espacial, pois os algoritmos de simulação capturam melhor os padrões de heterogeneidade geométricos modelados na imagem de treinamento, do que as ferramentas tradicionais de estatística de dois pontos; e
- iii. maior interação e controle do modelador sobre os resultados, pois as imagens de treinamento são interpretações que podem ser escolhidas pelo especialista de acordo com o conhecimento geológico local;

No capítulo 3 estas vantagens do método foram avaliadas na prática e os principais parâmetros utilizados na simulação de múltiplos pontos com algoritmo *SNESIM* foram testados, por meio de um estudo de caso em 2D do banco de dados *Walker Lake* modificado. A partir destes resultados experimentais verificou-se que:

- i. o algoritmo de múltiplos pontos *SNESIM* reproduziu menos ruídos (blocos dispersos) nas realizações, do que o algoritmo de estatística de dois pontos *SISIM*;
- ii. os padrões curvilíneos foram capturados pelo algoritmo *SNESIM*, mas não foram acessados pelas simulações com *SISIM*, como já era esperado;
- iii. o tempo de processamento do *SNESIM* para executar 100 simulações foi aproximadamente 50% menor, em comparação ao tempo gasto pelo *SISIM*;
- iv. a reprodução dos padrões geométricos pelo algoritmo *SNESIM* é afetada não somente pela imagem de treinamento, mas também pelos tamanhos e números de moldes; para o modelo em *2D* testado, os resultados foram mais satisfatórios com tamanhos de moldes isotrópicos; e
- v. a decisão sobre os parâmetros de distribuição marginal padrão e fator de ajuste dependem dos dados disponíveis e do conhecimento do modelador sobre o depósito.

No capítulo 4 foi apresentada uma metodologia para aplicação do algoritmo *SNESIM* em depósitos de minério de ferro, pois na prática comprovou-se que:

- i. a distribuição dos furos em uma região preferencial do depósito (área mineralizada) afeta a reprodução dos padrões;
- ii. padrões geométricos espacialmente não estacionários, comuns em depósitos de minério de ferro, quando informados em uma única imagem de treinamento, não são reproduzidos pelo algoritmo;
- iii. a inclusão de furos “fantasmas” ou seções como amostras primárias nas simulações, apesar de reproduzirem satisfatoriamente os padrões geométricos e de distribuição, são alternativas deterministas, que podem comprometer a quantificação da incerteza; e
- iv. as informações geológicas podem ser integradas probabilisticamente na simulação por meio de mapas de probabilidade utilizados como informações secundárias;

No capítulo 5 a metodologia proposta foi aplicada em um depósito de ferro brasileiro em 3D, a partir dos resultados constatou-se que:

- i. o algoritmo *SNESIM* acessou as interpretações geológicas do depósito de minério de ferro investigado, que foram integradas probabilisticamente como informações

- secundárias, e reproduziu de forma satisfatória, as distribuições esperadas para as extensas regiões não amostras interpretadas como estéril;
- ii. o modelo geológico simplificado, transformado em modelo de probabilidade, foi essencial para informar os aspectos globais de distribuições das tipologias no depósito, enquanto as decisão de estimativas locais foram baseadas nele, nas informações contidas na imagem de treinamento e nas amostras primárias;
 - iii. a decisão de utilizar as proporções do modelo simplificado (análogo) como proporção marginal, e não da imagem de treinamento ou dos furos de sondagem como investigado, resultou em proporções globais consistentes com o modelo interpretado;
 - iv. o algoritmo *SNESIM* pode ser utilizado nos estágios iniciais de pesquisa mineral com propósito de construir um modelo geológico de referência para elaboração do estudo de viabilidade econômica do depósito, com menor esforço operacional e de tempo; e
 - v. a incerteza sobre o modelo pode ser acessada e quantificada pela compilação das realizações resultantes da simulação com algoritmo *SNESIM*.

6.2. Trabalhos futuros

Para trabalhos futuros, que podem vir a dar seqüência a essa pesquisa, destacam-se as recomendações e sugestões:

- i. realizar simulações com várias imagens de treinamento, para modelar a incerteza sobre a interpretação dos padrões geométricos construídos nas imagens de treinamento; e
- ii. investigar a utilização de outros algoritmo de simulação de múltiplos pontos que possam ser aplicados em depósitos minerais, no *FILTERSIM*, por exemplo, novas formas de corrigir os limites abruptos gerados independentes em cada grid de simulação podem ser desenvolvidas e testadas.

Capítulo 7

Referências bibliográficas

- Alabert, F. G., 1987. **Stochastic imaging of spatial distributions using hard and soft information**. M.Sc. thesis, Stanford University, Stanford, CA, 197p.
- Alabert, F. G.; Massonnat, G. J. 1990. **Heterogeneity in a complex turbiditic reservoir: Stochastic modelling of facies and petrophysical variability**. In 65th Annual Technical Conference and Exhibition. Society of Petroleum Engineers.
- Alkimim, F. F.; Marshak, S., 1998. **Transamazonian orogeny in the Southern São Francisco Craton Region, Minas Gerais, Brazil: evidence for Paleoproterozoic collision and collapse in the Quadrilátero Ferrífero**. Precambrian Research, 90: 29-58.
- Almeida, F. F. M., 1977. **O Craton de São Francisco**. Revista Brasileira de Geociências, 7(4): 349- 364.
- Arpat, G. B., 2004. **SIMPAT: stochastic simulation with patterns**. 17 SCRF Meeting Stanford Center for Reservoir Forecasting, Stanford University.
- Arpat, G. B.; Caers, J., 2004. **Conditional simulation with patterns**. Mathematical Geosciences, 39(3): 177-203.
- Babinski, M.; Chemale Jr., F.; Van Schmus, W. R. 1995. **The Pb/Pb age of Minas Supergroup carbonate rocks, Quadrilátero Ferrífero, Brazil, and its implications to the correlation with BIFs from South Africa and Australia**. Precambrian Research, 72: 235-245.

- Bergerman, M. G., 2009. **Modelagem e simulação do circuito de moagem do Sossego**. Dissertação de mestrado. Escola Politécnica da Universidade de São Paulo, 208p.
- Boucher, A., 2009. **Considering complex training images with search tree partitioning**. Computers and geosciences, 35: 1151-1158.
- Boucher, A., 2012. **Shortcourse Multiple Point Simulation. Ar2tech**. Universidade Federal do Rio Grande do Sul.
- Caers, J., 2011. **Modeling uncertainty in the earth sciences**. Wiley-Blackwell, 246p.
- Caers, J; Zhang, T., 2004. **Multiple point geostatistics: a quantitative vehicle for integrating geologic analogs into reservoir models**. In: G. M. Grammer, P.M. Harris and G.P. Eberli, eds., Integration of outcrop and modern analogs in reservoir modeling, AAPG memoir, Tulsa, p. 338-394.
- Carneiro, M. A., 1995. **Geocronologia e geoquímica do Complexo Bonfim**. Tese de doutorado. Universidade de São Paulo.
- Champigny, N.; Armstrong, M., 1994. **An overview of reserve estimation problems by an international “Groupe de reflexion”**; Can. Inst. Min. Metall. Bull., no. 977, pp. 23-25.
- Chemale Jr., F.; Rosière, C. A.; Endo, I., 2004. **The tectonic evolution of the Quadrilátero Ferrífero, Minas Gerais, Brazil**. Precambrian Research, 65: 25-54.
- Chiles, J. P.; Delfiner, P., 1999. **Geostatistics: modeling spatial uncertainty. Wiley series in probability and statistics**. Applied probability and statistics section, New York, Wiley, 695p.
- Clow, G., 1991. **Why gold mines fail**. Northern Miner, February, pp. 31-34.
- Davis, M., 1987. **Production of conditional simulations via the LU decomposition of the covariance matrix**. Mathematical Geology, vol. 19, pp. 91-98.
- Deutsch, C. V. 1992. **Annealing techniques applied to reservoir modeling and the integration of geological and engineering (well test) data**. PhD. Thesis, Stanford University, 306p.

- Deutsch, C. V.; Journel, A. G. 1992. **Anneling techniques applied to the integration of geological and engineering data**. In Report 5, Stanford Center for Reservoir Forecasting, Stanford, CA.
- Dias, P. M., 2012. **O uso da densidade nas estimativas de teores de cobre e os impactos observados na reconciliação**. Dissertação de mestrado. Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e Materiais (PPGEM), Universidade Federal do Rio Grande do Sul.
- Diedrich, C., 2012. **Incorporação da variabilidade dos teores para análise de risco de recursos minerais e seqüenciamento de lavra**. Dissertação de mestrado. Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 126p.
- Dimitrakopoulos, R., 1998. **Conditional simulation algorithms for modelling orebody uncertainty in open pit optimization**. International Journal of Surface Mining, Reclamation and Environment. Number 12, pp. 173-179.
- Dorr, J. V. N., 1969. **Physiographic, stratigraphic and structural development of Quadrilátero Ferrífero, Minas Gerais**. U. S. Geol. Surv. 110p.
- Eschwege, W. L., 1833. **Pluto Brasiliensis**, Berlin. Verlag G. Reimer.
- Farmer, C., 1992. **Numerical rocks**. In P. R. King, editor. The mathematical generation of reservoir geology. Clarendon Press, Oxford.
- Goovaerts, P., 1997. **Geostatistics for natural resources evaluation**. Applied Geostatistics series, New York, Oxford University Press, 483p.
- Goovaerts, P.; Journel, A. G., 1996. **Accounting for local probabilities in stochastic modeling of facies data**. SPE Journal, 1(1):21-29.

- Guardiano, F.; Srivastava, R. M., 1993. **Multivariate geostatistics: beyond bivariate moments**. In: A. Soares, ed., *Geostatistics Troia 92*, v.1, Kluwer Academic Publishers, Dordrecht, p. 133-144.
- Guilbert, J. M.; Park, C. F., 1986. **The geology of ore deposits**. New York, W. H. Freeman and Co., 985p.
- Hardorsen, H. H.; Brand, P. J. e Macdonald, C. J., 1988. **Review of the stochastic nature of reservoirs**. In S. Edwards and P. R. King, editors, *Mathematics in Oil Production*. Clarendon Press, Oxford.
- Hill, V. G., 1977. **The mineralogy and genesis of bauxite deposit of Jamaica, BWI**. University of Toronto. pp. 276-288.
- Honarkhah, M.; Caers, J., 2010. **Stochastic simulation of patterns using distance-based pattern modeling**. *Mathematical Geosciences*, 42: 487-517.
- Isaaks, E. H; Srivastava, M. R., 1989. **An introduction to applied geostatistics**. Oxford University Press, New york, 561p.
- Issaks, E. H., 1990. **The application of Monte Carlo methods to the analysis of spatially correlated data**. Ph.D. thesis, Stanford University, Stanford, 213p.
- JORC, 2004: **Australasian code for reporting of mineral resources and ore reserves** (The JORC Code). AusIMM.
- Journel, A. G. 1983. **Non-parametric estimation of spatial distributions**. *Mathematical Geology*, 15(3): 445-468.
- Journel, A. G., 1974. **Geostatistics for conditional of ore bodies**. *Economic Geology*, pp. 673-687.
- Journel, A. G., 1989. **Fundamentals of geostatistics in five lessons**. Volume 8 Short Course in Geology. American Geophysical Union, Washington, D.C.

- Journal, A. G., 2004. **Beyond covariance: the advent of multiple-point geostatistics**. Geostats Banff 2004.
- Journal, A. G.; Huijbregts, C. J., 1978. **Mining Geostatistics**. Academic Press, New York, 600p.
- Journal, A. G.; Isaaks, E. H., 1984. **Conditional indicator simulation: application to a saskatchewan uranium deposit**. *Mathematical Geology*, 16(7): 685-718.
- Journal, A., 2000. **Stochastic imaging of channels from seismic data using multiple-point statistics**. In Report 13, Stanford Center for Reservoir Forecasting, Stanford, CA.
- King, H. F.; McMahon, D. W.; Bujtor, G. J. e Scott, A. K., 1986. **Geology in the understanding of ore reserve estimation: An Australian viewpoint**. In: D.E. Ranta, ed., *Ore reserve estimation*, Applied Mining Geology, Littleton, Colorado, SME.
- Knoll, K., 1989. **And now the bad news**; *Northern Miner*, June, pp. 48-52.
- Lobur, J. e Null, L., 2010. **Princípios básicos de arquitetura e organização de computadores**. 2ed. Porto alegre: Bookman. 821p.
- Maharaja, A., 2004. **Hierarchical simulation of multiple-facies reservoirs using multiple-point geostatistics**. M.Sc. thesis, Stanford University, Stanford, CA, 42p.
- Matheron, G., 1963. **Principles of geostatistics**. *Economic Geology*, v. 58, pp. 1246-1266.
- Matheron, G., 1972. **Quelques aspects de la montée**. Publication N-271, Centre de Géostatistique, École des Mines de Paris, Fontainebleau.
- Matheron, G., 1973. **The intrinsic random function and their applications**. *Advances in applied probability*, pp. 439-468.
- Matheron, G.; Beucher, H.; Fouquet, C.; Galli, A.; Guerillot, D.; Ravenne, C., 1987. **Conditional simulation of the geometry of fluvio-deltaic reservoirs**. SPE.

- MBR, 2005. **Minerações Brasileira Reunidas**. Relatório internos: Gerência de geologia e planejamento operacional.
- Monteiro, L. V. S.; Xavier, R. P., Hitzman, M. W.; Juliani, C.; Filho, C. R. S.; Carvalho, E. R., 2008. **Mineral chemistry of ore and hydrothermal alteration at the Sossego iron oxide-copper-gold deposit, Carajás Mineral Province, Brazil**. Ore Geology Reviews 34, pp. 317-336.
- Moraes, J. L., 2004. **Simulação de fragmentação dos desmontes de rochas por explosivos**. Tese de Doutorado. Curso de Pós-Graduação em Engenharia Metalúrgica e de Minas. Universidade Federal de Minas Gerais, 224p.
- Noble, A. C., 1992. **Ore reserve/resource estimation**. SME Mining Engineering Handbook, Section 5, Hartman and D.E. Ranta, eds., AIME, New York, 2ed. 344p.
- Osterholt, V., 2006. **Simulation ore deposit geology and an application at the Yandicoogina iron ore deposit, Western Australia**. The degree of Master. The University of Queensland. 144p.
- Pasti, H. A., 2012. **Geoestatística de múltiplos pontos como ferramenta para modelagem geológica de depósitos minerais**. Dissertação de mestrado. Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 87p.
- Peroni, R. L., 2002. **Análise de sensibilidade do seqüenciamento de lavra em função da incerteza geológica**. Tese de Doutorado. Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 126p.
- Remy, N.; Boucher, A.; Wu, J., 2009. **Applied geostatistics with SGeMS: a user's guide**. Cambridge University Press, UK, 264p.
- Ribeiro, D. T., 2003. **Enriquecimento supergênico de Formações Ferríferas Bandadas: estruturas de colapso e desordem**. Tese de Doutorado. Programa de Pós-Graduação em Geologia da Universidade Federal do Rio de Janeiro.

- Richmond, A. J., 2004. **Financially efficient mining decisions incorporating grade uncertainty**. PhD Thesis, Imperial College, London, 208p.
- Ripley, B. D., 1987. **Stochastic Simulation**. John Wiley & Sons, New York, 237p.
- Roldão, D.; Ribeiro, D.; Cunha, E.; Noronha, R.; Madsen, A.; Masetti, L. 2012. **Combined use lithological and grade simulations for risk analysis in iron ore, Brazil**. Geostatistics Oslo 2012. 559p.
- Rosa, M. N.; Rodrigues, W. J., 2009. **Flotação do cobre no Sossego** (Companhia Vale do Rio Doce). Teoria e prática do tratamento de minérios, v. 4.
- Rosière, C. A.; Chamale Jr., F., 2000. **Itabiritos e minérios de ferro de alto teor do Quadrilátero Ferrífero: uma visão geral e discussão**. Geonomos 8 (2): 27-43.
- Sides, E. J., 1992. **Modeling of geological discontinuities for reserve estimation purposes at Neves-Corvo, Portugal**; R., and J. W. Ed. Computer graphics in geology: three dimensional modeling of geological structures and simulating geologic processes, Lecture notes in earth sciences, Springer-Verlag, Berlin.
- Soares, A., 1990. **Geostatistical estimation of orebody geometry: morphological kriging**. Mathematical Geosciences.
- Souza, F. S., 2007. **Uso de métodos geostatísticos no auxílio do modelamento geológico**. Dissertação de mestrado. Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 172p.
- Spier, C. A.; Oliveira, S. M., B.; Rosière, C. A. 2003. **Geology and geochemistry of the Águas Claras and Pico Iron Mines, Quadrilátero Ferrífero, Minas Gerais, Brazil**. Mineralium Deposita, 38: 751-774.
- Straubhaar, J.; Renard, P.; Marietroz, G.; Froidevaux, R., Besson, O., 2011. **An improved multiple-point algorithm using a list approach**. Mathematical Geosciences, 43(3): 305-328.

- Strebelle, S. 2002. **Conditional simulation of complex geological structures using multiple-point statistic**. *Mathematical Geology*, v. 34, p. 1-21.
- Strébelle, S., 2000. **Sequential simulation drawing structures from training images**. PhD Thesis. Stanford University.
- Strebelle, S.; Zhang, T., 2004. **Non-stationary multiple-point geostatistical models**. *Geostats Banff 2004*.
- Suro-Pérez, V., 1991. **Generation of a turbiditic reservoir: the boolean alternative**. In Report 4, Stanford Center for Reservoir Forecasting, Stanford, CA.
- Thwaites, A. M., 1998. **Assessment of geological uncertainty for a mining project**. 27th APCOM. pp. 391-404.
- Wu, J.; Boucher, A.; Zhang, T., 2008. **A SGeMS code for pattern simulation of continuous and categorical variables: FILTERSIM**. *Computers and geosciences*, 34: 1863-1876.
- Xu, W.; Journel, A. G. 1993. **Gtsim: gaussian truncated simulation of lithofacies**. In Report 6, Stanford Center for Reservoir Forecasting, Stanford, CA.
- Zhang, T.; Journel, A., 2008. **Fast FILTERSIM simulation with score based distance**. *Mathematical Geosciences*, 40: 773-788.

ANEXOS

(A) Parâmetros utilizados na simulação com SISIM e SNESIM

Walker SISIM

RunGeostatAlgorithm

```
sisim::/GeostatParamUtils/XML::<parameters>      <algorithm      name="sisim"      />
<Variogram_Median_Ik      nugget="0.006762"      structures_count="1"      > <structure_1
contribution="0.08" type="Spherical" > <ranges max="150" medium="60" min="1" /> <angles
x="157" y="0" z="0" /> </structure_1> </Variogram_Median_Ik> <Variogram_Full_Ik
nugget="0" structures_count="1" > <structure_1 contribution="0" type="Spherical" > <ranges
max="0" medium="0" min="0" /> <angles x="0" y="0" z="0" /> </structure_1>
</Variogram_Full_Ik> <Variogram_Full_Ik_2 nugget="0" structures_count="1" > <structure_1
contribution="0" type="Spherical" > <ranges max="0" medium="0" min="0" /> <angles x="0"
y="0" z="0" /> </structure_1> </Variogram_Full_Ik_2> <Hard_Data_Grid value="walker"
region="" /> <Hard_Data_Property value="t" /> <Assign_Hard_Data value="1" /> <coded_grid
value="" region="" /> <coded_props count="0" value="" /> <Max_Conditioning_Data
value="20" /> <Search_Ellipsoid value="150 60 1 157 0 0" /> <AdvancedSearch
use_advanced_search="0"></AdvancedSearch> <Grid_Name value="grid sisim" region="" />
<Property_Name value="sisim" /> <Nb_Realizations value="100" /> <Seed value="14071789"
/> <Categorical_Variable_Flag value="1" /> <Nb_Indicators value="2" />
<Marginal_Probabilities value="0.9 0.1" /> <lowerTailCdf function = "Power" extreme = "0"
omega = "3" /> <upperTailCdf function = "Power" extreme = "0" omega = "0.333" />
<Median_Ik_Flag value="1" /> <Full_Ik_Flag value="0" /> </parameters>
```

completing RunGeostatAlgorithm took 5928ms

Walker SNESIM

```
RunGeostatAlgorithm      snesim_std::/GeostatParamUtils/XML::<parameters>      <algorithm
name="snesim_std" /> <Cmin value="1" /> <Constraint_Marginal_ADVANCED value="0.8" />
<resimulation_criterion      value="-1"      /> <resimulation_iteration_nb      value="1"      />
<Nb_Multigrids_ADVANCED      value="3"      /> <Debug_Level value="0" /> <Subgrid_choice
value="0" /> <expand_isotropic value="1" /> <expand_anisotropic value="0" /> <aniso_factor
value=" " /> <Use_Affinity value="0" /> <Use_Rotation value="0" /> <Hard_Data
grid="walker" region="" property="t" /> <use_pre_simulated_gridded_data value="0" />
<Use_ProbField value="0" /> <ProbField_properties count="0" value="" /> <TauModelObject
value="1 1" /> <use_vertical_proportion value="0" /> <GridSelector_Sim value="grid snesim
ti2" region="" /> <Property_Name_Sim value="ti2" /> <Nb_Realizations value="100" /> <Seed
```

```
value="211175" /> <PropertySelector_Training grid="ti2" region="" property="ti2" />
<Nb_Facies value="2" /> <Marginal_Cdf value="0.9 0.1" /> <Max_Cond value="60" />
<Search_Ellipsoid value="30 30 1 0 0 0" /> </parameters>
```

Search tree size = 585 Search tree size = 4040

completing RunGeostatAlgorithm took 3370ms

(B) Parâmetros utilizados na simulação do SNESIM com informações secundárias

Walker modificado

```
RunGeostatAlgorithm    snesim_std::/GeostatParamUtils/XML::<parameters>    <algorithm
name="snesim_std" />    <Hard_Data grid="walker" region="" property="t" />
<use_pre_simulated_gridded_data value="0" />    <Use_ProbField value="0" />
<ProbField_properties count="0" value="" />    <TauModelObject value="1 1" />
<use_vertical_proportion value="0" />    <Use_Affinity value="0" />    <Use_Rotation value="0" />
<GridSelector_Sim value="factor ti2" region="" />    <Property_Name_Sim value="hd_0.5" />
<Nb_Realizations value="5" />    <Seed value="211175" />    <PropertySelector_Training grid="ti2"
region="" property="ti2" />    <Nb_Facies value="2" />    <Marginal_Cdf value="0.9 0.1" />
<Max_Cond value="60" />    <Search_Ellipsoid value="30 30 1 0 0 0" />    <Cmin value="1" />
<Constraint_Marginal_ADVANCED value="0.5" />    <resimulation_criterion value="-1" />
<resimulation_iteration_nb value="1" />    <Nb_Multigrids_ADVANCED value="3" />
<Debug_Level value="0" />    <Subgrid_choice value="0" />    <expand_isotropic value="1" />
<expand_anisotropic value="0" />    <aniso_factor value=" " /> </parameters>
```

Search tree size = 585 Search tree size = 4040

completing RunGeostatAlgorithm took 206ms

(C) Parâmetros utilizados no algoritmo SNESIM aplicados na simulação do depósito de ferro em 3D

```
RunGeostatAlgorithm    snesim_std::/GeostatParamUtils/XML::<parameters>    <algorithm
name="snesim_std" /> <Hard_Data grid="dataset 100" property="COD" region="" />
<use_pre_simulated_gridded_data value="0" /> <Use_ProbField value="1" />
<ProbField_properties count="2" value="soft_was3 Moving_average;soft_hem3
Moving_average_0_0_0" /> <TauModelObject value="1 1" /> <use_vertical_proportion
value="0" /> <Use_Affinity value="0" /> <Use_Rotation value="0" /> <Cmin value="5" />
<Constraint_Marginal_ADVANCED value="0.5" /> <resimulation_criterion value="-1" />
<resimulation_iteration_nb value="1" /> <Nb_Multigrids_ADVANCED value="3" />
<Debug_Level value="0" /> <Subgrid_choice value="0" /> <expand_isotropic value="1" />
<expand_anisotropic value="0" /> <aniso_factor value=" " /> <GridSelector_Sim value="grid
simulation" region="iron" /> <Property_Name_Sim value="iron" /> <Nb_Realizations
value="100" /> <Seed value="211175" /> <PropertySelector_Training grid="ti grid"
property="ti" region="iron" /> <Nb_Facies value="3" /> <Marginal_Cdf value="38.3 59.2 2.5"
/> <Max_Cond value="80" /> <Search_Ellipsoid value="50 50 50 0 0 0" /> </parameters>
```

[completing RunGeostatAlgorithm took 21013108ms](#)