UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE GEOCIÊNCIAS

**Análise de incertezas do modelo de teores associada aos investimentos de
pesquisa de longo prazo**

TALITA CRISTINA DE OLIVEIRA FERREIRA

Orientador: Prof. Dr. Marcelo Monteiro da Rocha

DISSERTAÇÃO DE MESTRADO
Programa de Pós-Graduação Recursos Minerais e Hidrogeologia

São Paulo
2016

Versão Corrigida

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE GEOCIÊNCIAS

**ANÁLISE DE INCERTEZAS DO MODELO DE TEORES ASSOCIADA AOS
INVESTIMENTOS DE PESQUISA DE LONGO PRAZO**

TALITA CRISTINA DE OLIVEIRA FERREIRA

Dissertação apresentada ao Instituto de
Geociências da Universidade de São
Paulo para obtenção de título de Mestre
em Recursos Minerais.

Orientador: Prof. Dr. Marcelo Monteiro
da Rocha

São Paulo

2016

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer outro meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Ficha catalográfica preparada pelo Serviço de Biblioteca e Documentação do Instituto de Geociências da Universidade de São Paulo

Ferreira, Talita Cristina de Oliveira

Análise de incertezas do modelo de teores associado aos investimentos de pesquisa de longo prazo. / Talita Cristina de Oliveira Ferreira. - São Paulo, 2016.

88 p.: + anexos

Dissertação (Mestrado) : IGc/USP

Orient.: Rocha, Marcelo Monteiro da

1. Geoestatística 2. Simulação condicional 3. Recursos minerais 4. Análise de incertezas I.
Título

DEDICATÓRIA

Dedico este trabalho aos meus pais que,
mesmo nas dificuldades, encontram forças para
lutar. Admiro e amo muito vocês.

AGRADECIMENTOS

Inicialmente gostaria de agradecer a todas as instituições e pessoas que forneceram o suporte necessário ao desenvolvimento desta dissertação:

- ao Instituto de Geociências e todos seus funcionários e professores. Foi muito bom perceber que mesmo depois de alguns anos, os funcionários de sempre lembram de você e do seu nome;
- à empresa Vale S.A., pela disponibilização dos dados, em especial ao engenheiro Sandro Freitas que prontamente se mostrou disposto a compartilhar as informações e conhecimento;
- à CAPES pelo breve período de bolsa;
- à Votorantim Metais pela liberação do uso dos softwares utilizados neste trabalho e;
- ao professor Marcelo Monteiro da Rocha, que desde o início desta empreitada esteve disposto a entender minhas ausências e esclarecer dúvidas que, na maioria das vezes, eram de iniciantes. Muito obrigada.

E como não poderia deixar de fazer, preciso citar alguns dos amigos que, mesmo à distância contribuíram, e muito, para o desenvolvimento deste trabalho: Gabriela Ciantelli, Patricia Gonçalves Guimarães, Gustavo Usero. Suas dicas preciosas e conversas animadoras foram de grande valia à conclusão deste trabalho. Além destes, agradeço muito a todos aqueles da turma de Geo 2003. Nem parece, mas já se passaram mais de 10 anos de amizade e convívio prazeroso. São muitos os nomes que deveria citar aqui, então, para evitar esquecimento, fica apenas o: muito obrigada, galera!

Agradecer em especial a Ana Paula Chiquini que, desde o início do convívio na extinta Yamana, compartilhou sonhos, alegrias e tristezas. Foram muitos momentos vividos, muita geoestatística discutida. Infelizmente, a vida não consegue ser tão bem “estimada” quanto nossos modelos, mas no meio de tantas incertezas, pelo menos com as dessa vida, conseguimos conviver bem.

Meus pais queridos, Vera e Valdemir. Mesmo não sabendo explicar o que faço, entendem e me apoiam incondicionalmente. Sem vocês não teria forças para prosseguir e, mesmo longe, sempre os levarei em meus pensamentos, por onde quer que eu vá.

Por último e, não menos importante, ao mais novo professor doutor, Matheus. Foram anos difíceis, permeados de mudanças, alguns momentos juntos, outros não, mas, sempre ao meu lado. Este trabalho certamente não teria sido finalizado sem suas preciosas observações de

conteúdo e forma. Este ano de 2016 já começou com muitas notícias boas e com certeza terminarão repletos de momentos especiais. Muito obrigada por tudo!

EPÍGRAFE

“For every complex problem there is an answer that is clear, simple, and wrong!”

H. L. Mencken

RESUMO

FERREIRA, T. C. O. Análise de incertezas do modelo de teores associada aos investimentos de pesquisa de longo prazo. 2016. Dissertação (Mestrado) – Instituto de Geociências, Universidade de São Paulo, São Paulo, 2016.

Os empreendimentos de mineração comumente demandam grande quantidade de investimentos financeiros e, na maioria das vezes, longos períodos de implantação, o que os torna altamente sujeitos a diversas fontes de incertezas. Tais incertezas comumente tendem a diminuir conforme a evolução do projeto. O objetivo deste estudo é correlacionar as incertezas associadas ao modelo de teores de cobre do depósito Sequeirinho com o volume de investimentos realizados ao longo de distintas fases da pesquisa geológica. Este depósito insere-se no contexto do Complexo de Mineração Sossego, localizado no município de Canaã dos Carajás (PA). Primeiramente, foram realizadas 100 simulações para cada domínio litológico em cada campanha de sondagem (pré-1998, 1999, 2000, 2002 e 2003) a partir do método de simulação sequencial gaussiana condicionada aos dados amostrais, totalizando 1.400 possíveis cenários. Para a avaliação das incertezas foram calculados três índices: variância condicional, coeficiente de variação condicional e intervalo interquartil. Por fim, a avaliação dos investimentos foi elaborada a partir dos custos estimados para o desenvolvimento de sondagens e análises químicas. Desde a campanha pré-1998, houve uma tendência de os teores médios do depósito aproximarem-se dos prováveis valores reais observados nas fases finais da pesquisa. No ano de 2000 ocorreu o maior investimento (cerca de 28 milhões de Reais) e a redução das incertezas atingiu o patamar de 15%. Os investimentos desenvolvidos em sondagens posteriores à campanha de 2000 foram da ordem de 9 milhões de Reais (cerca de 12 mil metros de sondagem), porém, não foram constatadas reduções significativas das incertezas. Este investimento seria melhor aproveitado caso fosse redirecionado a novas áreas de prospecção. Além do montante financeiro necessário para a redução das incertezas, foco deste estudo, as variações na interpretação geológica e a locação dos furos de sondagem são variáveis importantes na análise de incertezas associadas aos investimentos em pesquisa geológica.

Palavras-chave: geoestatística, simulação condicional, recursos minerais, análise de incertezas.

ABSTRACT

FERREIRA, T. C. O. Uncertainty analyses of grade models related with long term resources. 2016. 90 f. Dissertação (Mestrado) – Instituto de Geociências, Universidade de São Paulo, São Paulo, 2016.

Mining projects require large amount of capital investment and most cases spend long periods of implementation, which make them extremely susceptible to several sources of uncertainty. Such uncertainties commonly tend to decrease along the project development. The present study aims to correlate the uncertainties associated to the grade model of the Sequeirinho copper mine with the amount of capital investment that has been spent along different geological surveys. Sequeirinho site is included in the context of Sossego Mine Complex, located in Canaã dos Carajás (PA, Brazil). Initially, 100 simulations were carried out for each lithologic domain in each drilling campaign (pre-1998, 1999, 2000, 2002 and 2003) using sequential Gaussian simulation conditioned to the sample, resulting in 1,400 possible scenarios. Three indexes were calculated for the uncertainty analysis: conditional variance, conditional coefficient variance and interquartile range. Finally, the evaluation of capital investment was elaborated from the costs estimated for drilling and chemical analysis. Since pre-1998 drilling campaign, deposit average grades have showed a trend to get closer to the possible real values observed in the final research surveys. In 2000, there was the biggest capital investment (about R\$ 28 millions) and the uncertainty reduction has reached the maximum level of 15%. Investments performed in drilling programs after 2000 were around R\$ 9 million (around 12,000 meters of drill holes), but the uncertainty reduction was not significant. Therefore, such investments might be used to discover new targets. Besides the correlation of uncertainty reduction and amount of capital investment, the main focus of this study, the uncertainty of geological model and the drillhole locations are important variables to be considered in investment analysis of geological survey.

Key words: geostatistics, conditional simulation, mineral resources, uncertainty analysis.

LISTA DE FIGURAS

Figura 2.1 – Curva normal típica (modificado de Correa, 2003)	9
Figura 2.2 – Função de densidade de probabilidade (fdp) lognormal (modificado de Journel, 1989)..	10
Figura 2.3 – Esquema de construção do Box Plot.....	11
Figura 2.4 – Histograma para dados da variável U	11
Figura 2.5 – Relação entre a função variograma e a função covariância (modificado de Olea, 1994) .	14
Figura 2.6 – Semi-variograma experimental para 2 direções.....	15
Figura 2.7 – Representação de um variograma típico com patamar e suas propriedades. (Yamamoto, 2001).....	16
Figura 2.8 – Exemplos de modelos de variograma (Goovaerts ,1997)	18
Figura 2.9 – Transformação gaussiana a partir de função de distribuição acumulada (Rossi & Deutsch, 2014).....	28
Figura 2.10 – Exemplo de ajuste da função anamorfose (Neufeld, 2005)	29
Figura 2.11 – Teste de binormalidade. Razão madograma/variograma de uma base de dados fictícia	30
Figura 3.1 – Comparação entre modelo estimado e modelo simulado (Deutsch & Rossi, 2014)	38
Figura 3.2 – (A) Mapa geológico simplificado da região do Complexo de Mineração Sossego (modificado de VALE por Monteiro <i>et al.</i> , 2008); (B) Distribuição esquemática das zonas de alteração hidrotermais na Mina Sossego (Monteiro <i>et al.</i> , 2008a).....	40
Figura 3.3 – Seção esquemática do corpo Sequeirinho com destaque às zonas de alteração hidrotermais. Modificada de Monteiro <i>et al.</i> , 2008a	41
Figura 3.4 – Proporção de número de sondagem rotativa por campanha.....	42
Figura 3.5 – Mapa em 2D da localização das distintas campanhas de sondagem.....	42
Figura 3.6 – Topografia 3D da área em estudo indicando localização dos furos e unidades geológicas (Datamine Studio 3D®).....	43
Figura 3.7 – Seção vertical esquemática (S-N) do modelo de blocos 2D com definição da geologia local	44
Figura 3.8 – Fluxograma de atividades da pesquisa.....	47
Figura 4.1 – Mapa de distribuição de litologias no modelo de blocos	48
Figura 4.2 – Gráfico de distribuição de probabilidade dos dados originais (<i>p-plot</i>) para campanha 2003	51
Figura 4.3 – Histograma de distribuição das espessuras das amostras originais.....	52
Figura 4.4 – Análise de contato entre as principais litologias. Dados da campanha 2003	53
Figura 4.5 – Boxplot da distribuição de Cu (%) por litologia, campanha 2003	53
Figura 4.6 – Histograma para os dados compositados da campanha 2003	55
Figura 4.7 – Modelo teórico ajustado para domínio intermediário – Grupo 1	56

Figura 4.8 – Modelo teórico ajustado para domínio de baixo teor – Sulfeto Disseminado	57
Figura 4.9 – Modelo teórico ajustado para domínio de alto teor – Brecha Sulfetada	58
Figura 4.10 – Histograma dos teores de Cu (%) estimados no modelo de blocos	59
Figura 4.11 – Mapa de teores em 2D dos teores no modelo de blocos	60
Figura 4.12 – Análise de deriva para o eixo X para as litologias de Sulfeto Disseminado (<i>low grade</i>), Brecha Sulfetada (<i>high grade</i>) e Grupo 1.....	61
Figura 4.13 – (a) função experimental anamorfose (preto) e modelo expandido da função original em termos do polinômio Hermite (magenta); (b) Histograma dos valores originais de Cu (preto) e valores resultantes do processo de transformação (rosa).....	63
Figura 4.14 – Teste de binormalidade através da razão variograma ² /madograma. Dados campanha 2003	64
Figura 4.15 – Modelo de variograma omnidirecional ajustado para dados do Grupo 1, campanha 2003	65
Figura 4.16 – Modelo de variograma ajustado nas principais direções anisotrópicas para dados referentes ao domínio Sulfeto Disseminado, campanha 2003.....	65
Figura 4.17 – Modelo de variograma ajustado nas principais direções anisotrópicas para o domínio Brecha Sulfetada, campanha 2003.....	66
Figura 4.18 – Gráficos de validação da média para os valores médios simulados na campanha de 2003	68
Figura 4.19 - Histogramas de validação domínio Sulfeto Disseminado, campanha 2003	69
Figura 4.20 - Histogramas de validação para domínio Brecha Sulfetada, campanha 2003	69
Figura 4.21 – Mapa de distribuição de teores simulados por campanha.....	71
Figura 4.22 – Probabilidade da ocorrência de tores acima do <i>cutoff</i> aleatório de 1% Cu.....	72
Figura 4.23 – Distribuição de amostras no modelo de blocos por campanha	73
Figura 4.24 – Boxplot dos teores médios de Cu (%) para distintas campanhas de sondagem referentes ao domínio de baixo teor (Sulfeto Disseminado)	75
Figura 4.25 – Boxplot de teores médios de Cu (%) para distintas campanhas de sondagem referentes ao domínio de alto teor (Brecha Sulfetada).....	75
Figura 4.26 – Custos estimados para desenvolvimento de campanha de sondagem.....	77
Figura 4.27 – Estimativa de custos e total de metros perfurados	78
Figura 4.28 – Relação investimentos vs. incertezas das distintas campanhas	79

LISTA DE TABELAS

Tabela 3.1 – Lista de litotipos considerados na subdivisão dos dados.....	44
Tabela 4.1 – Estatística descritiva dos dados originais. Apenas litologias mineralizadas.	50
Tabela 4.2 – Descrição dos domínios definidos para análise geoestatística.	54
Tabela 4.3 – Estatísticas descritivas dos domínios geoestatísticos para as amostras regularizadas e desagrupadas.	54
Tabela 4.4 – Parâmetros do modelo teórico de variograma ajustado para dados da campanha 2003... ..	56
Tabela 4.5 – Parâmetros de vizinhança para estimativa por krigagem ordinária	59
Tabela 4.6 – Estatística básica do modelo estimado por krigagem ordinária.....	60
Tabela 4.7 - Parâmetros do modelo teórico de variograma ajustado para dados da campanha 2003. ..	66
Tabela 4.8 - Parâmetros de vizinhança de simulação.....	67
Tabela 4.9 - Parâmetros de incerteza resumidos para os respectivos litotipos simulados.....	74
Tabela 4.10 – Gastos estimados desembolsados nas distintas campanhas.....	77

SUMÁRIO

DEDICATÓRIA	I
AGRADECIMENTOS	II
EPÍGRAFE	IV
RESUMO	V
ABSTRACT	VI
LISTA DE FIGURAS	VII
LISTA DE TABELAS	IX
CAPITULO 1 – INTRODUÇÃO E OBJETIVOS	1
1.1 INTRODUÇÃO	1
1.2 OBJETIVOS	2
CAPITULO 2 – FUNDAMENTAÇÃO TEÓRICA	4
2.1 REVISÃO DOS CONCEITOS ESTATÍSTICOS	4
2.1.1 <i>Noção de População e Amostra</i>	4
2.2 AS VARIÁVEIS ALEATÓRIAS	6
2.2.1 <i>Características das variáveis aleatórias</i>	6
2.3 DISTRIBUIÇÃO DE FREQUÊNCIAS	8
2.3.1 <i>Distribuição Normal ou Gaussiana</i>	8
2.3.2 <i>Distribuição Lognormal</i>	9
2.4 REPRESENTAÇÕES GRÁFICAS	10
2.5 REVISÃO DOS CONCEITOS GEOESTATÍSTICOS	12
2.5.1 <i>Função Variograma</i>	13
2.5.1.1 <i>Propriedades do variograma</i>	15
2.5.2 <i>Principais modelos teóricos de variograma</i>	16
2.6 MÉTODOS DE ESTIMATIVA	18
2.6.1 <i>Krigagem simples (KS)</i>	20
2.6.2 <i>Krigagem Ordinária (KO)</i>	22
2.7 MÉTODOS DE SIMULAÇÃO ESTOCÁSTICA	22
2.7.1 <i>Simulação Sequencial Condicional</i>	24
2.7.2 <i>Simulação Sequencial Gaussiana (SGS)</i>	25
2.7.2.1 <i>Transformação Gaussiana</i>	27
2.7.2.2 <i>Verificação da multigaussianidade (binormalidade)</i>	29
2.8 INCERTEZAS NA ESTIMATIVA DE RECURSOS	30
2.8.1 <i>Métodos utilizados na avaliação das incertezas</i>	32
2.8.1.1 <i>A variância de krigagem</i>	32
2.8.1.2 <i>Variância de interpolação</i>	34

2.8.2	<i>Distribuição local de probabilidade</i>	35
2.8.2.1	Variância condicional	35
2.8.2.2	Coeficiente de variação condicional (CV)	36
2.8.2.3	Intervalo entre quartil condicional (IEQ)	37
CAPITULO 3 – MATERIAIS E MÉTODOS UTILIZADOS		38
3.1	BASE DE DADOS	39
3.1.1	<i>Contexto geológico da área de estudo</i>	39
3.1.2	<i>Banco de dados</i>	41
3.1.3	<i>Topografia</i>	43
3.1.4	<i>Modelo de Blocos</i>	43
3.2	PREMISSAS ADOTADAS	45
3.3	METODOLOGIA PROPOSTA	45
CAPITULO 4 – RESULTADOS E DISCUSSÃO		48
4.1	VALIDAÇÃO DA BASE DE DADOS	48
4.2	ANÁLISE EXPLORATÓRIA DOS DADOS	49
4.2.1	<i>Dados brutos (Raw Data)</i>	49
4.2.1	<i>Dados regularizados (Composite Data)</i>	51
4.2.2	<i>Análise dos dados</i>	52
4.2.3	<i>Análise estatística dos dados regularizados</i>	54
4.3	ESTIMATIVA DO MODELO POR KRIGAGEM ORDINÁRIA	55
4.3.1	<i>Análise Variográfica</i>	56
4.3.2	<i>Parâmetros de estimativa e modelo estimado</i>	58
4.3.3	<i>Validação do modelo estimado</i>	60
4.4	SIMULAÇÃO SEQUENCIAL GAUSSIANA (SGS)	62
4.4.1	<i>Transformação dos dados para distribuição gaussiana (anamorfose)</i>	62
4.4.2	<i>Análise variográfica dos dados transformados</i>	64
4.4.3	<i>Parâmetros da simulação</i>	67
4.4.4	<i>Validação dos resultados</i>	67
4.4.5	<i>Imagens equiprováveis e intervalos de probabilidade</i>	70
4.5	COMPARAÇÃO ENTRE DISTINTOS NÍVEIS DE INCERTEZAS	73
4.6	COMPARAÇÃO ENTRE VALORES MÉDIOS OBTIDOS POR SIMULAÇÃO E KRIGAGEM ORDINÁRIA	74
4.7	AValiação DE CUSTOS DA PESQUISA GEOLÓGICA	76
4.8	CORRELAÇÃO INCERTEZAS VS. INVESTIMENTO FINANCEIRO	78
CAPITULO 5 – CONCLUSÕES		80
REFERENCIAS BIBLIOGRÁFICAS		82
ANEXO A – Histograma Dados Brutos		89
ANEXO B – Gráficos de Probabilidade		91
ANEXO C – Boxplot dos Dados Compositados		93

ANEXO D – Histograma dos Dados Compositados	95
ANEXO E – Mapa de Análise Variográfica em Superfície	97
ANEXO F – Validação por Médias Móveis da Krigagem Ordinária	99
ANEXO G – GRÁFICOS DE AJUSTE DE FUNÇÃO ANAMORFOSE E HISTOGRAMAS DAS VARIÁVEIS TRANSFORMADAS	102
ANEXO H – Gráficos de Validação da Simulação	109
ANEXO I – Variogramas Experimentais e Modelos Ajustados.....	111
ANEXO J – Parâmetros de Vizinhaça Utilizados na Simulação.....	117
ANEXO K – Valores Médios das Simulações vs. Valor Médio Obtido na Krigagem Ordinária .	118
ANEXO L – Histogramas de Validação	122

CAPITULO 1 – INTRODUÇÃO E OBJETIVOS

1.1 Introdução

A análise de incerteza em empreendimentos de mineração é tema bastante recorrente em diversos trabalhos devido a este tipo de empreendimento envolver uma série de riscos. Comumente, os empreendimentos de mineração demandam alto volume de investimento financeiro e, na maioria das vezes, longos períodos de implantação, tornando-os altamente sujeitos a diversas fontes de incertezas ao longo do tempo, como por exemplo, variações no preço da *commoditie*, variações macroeconômicas, políticas, entre outras.

Na implementação de um empreendimento mineiro, diversos autores (Trigeorges, 1996, Maia, 2001; Silva, 2008) e profissionais da área desenvolveram estudos que demonstram que decisões baseadas apenas em avaliações estáticas (que consideram apenas um cenário imutável) e que desconsideram possíveis riscos e incertezas envolvidas poderiam ocasionar o fechamento de empresas e a desistência de bons projetos que, se avaliados de forma correta, podem resultar em grandes empreendimentos.

Neste tipo de negócio, as incertezas tendem a diminuir conforme o projeto evolui. Na etapa inicial de prospecção geológica, os investimentos iniciais dão ideia da potencialidade do depósito em questão e, a partir dos resultados encontrados nesta etapa, decide-se sobre investir ou não em determinada área. Neste sentido é papel dos investidores avaliar os riscos e benefícios envolvidos no negócio.

Com a decisão de dar continuidade ao projeto, parte-se para a fase de pesquisa mineral, onde são efetuadas a coleta de amostras em subsuperfície, as análises químicas dos testemunhos de sondagem, a elaboração do banco de dados, a definição do modelo geológico tridimensional e a quantificação do minério em termos de teores e tonelagens.

A partir desta etapa, as ocorrências minerais podem ser efetivamente categorizadas como recursos minerais que poderão futuramente ser explorados. De forma simplificada, entende-se por Recursos Minerais concentrações ou ocorrências de bens minerais de interesse econômico disponíveis na crosta terrestre em quantidade e qualidade adequadas à eventual extração econômica (AusIMM, 2012).

Existem diversos níveis de categoria de recursos minerais, sendo cada um deles correlacionado ao grau de confiança dos dados que são mensurados em relação a diversos fatores, como a quantidade de dados de sondagem, quantidade de amostras coletadas,

qualidade da geometrização do depósito (modelo geológico), avaliação dos teores, etc. A partir disto, a credibilidade do depósito dependerá da quantidade de informações existentes, ou seja, quanto maior o número de dados disponíveis, menores serão as incertezas relacionadas e maior será a confiabilidade dos valores previstos.

Sabendo-se da limitação financeira dos investimentos para a coleta de dados massiva e que aumente a quantidade e confiabilidade dos recursos minerais, diversos trabalhos na área da geoestatística buscam minimizar ao máximo as incertezas associadas às etapas de quantificação e qualificação dos recursos.

Neste sentido, as técnicas geoestatísticas clássicas, aplicadas desde meados do século XX, não refletem precisamente os fenômenos geológicos que são cercados por uma série de incertezas a respeito das variáveis geológicas. Por isso, já no final do mesmo período, uma ferramenta que surgiu como alternativa foi a simulação estocástica (Matheron, 1973), que oferece bom embasamento à avaliação das incertezas geológicas, uma vez que possibilita a observação de distintos resultados dentro de um intervalo de possíveis valores, permitindo, então, inferir as incertezas globais ao depósito.

Esta dissertação se propõe a avaliar as incertezas do depósito de cobre inserido no contexto do Complexo de Mineração Sossego, localizado no município de Canaã dos Carajás, sudeste do estado do Pará, Brasil e que atualmente é explorada pela empresa Vale S.A.. Os dados considerados neste trabalho são restritos à cava Sequeirinho e apresentam um histórico de investimentos em pesquisa desde 1997 e, portanto, fornecem distintos cenários propícios à avaliação da relação entre a redução das incertezas e o aumento do investimento financeiro em pesquisa. A avaliação destas incertezas será baseada em métodos de simulação geoestatística condicionada e, por sua vez, a perspectiva dos custos envolvidos será estimada com base em orçamento fictício elaborado a partir da cotação média dos valores referentes a cada etapa considerada.

1.2 Objetivos

O objetivo geral desta dissertação consiste em correlacionar as incertezas associadas ao modelo de teores com o volume de informações acumuladas ao longo de distintas fases da pesquisa geológica.

A partir da adoção dos procedimentos expostos nesta dissertação, objetiva-se ainda, reafirmar a importância da inserção dos valores de incertezas aos modelos de recursos e

ressaltar a relevância do acúmulo histórico de informações ao longo da vida útil de projetos de pesquisa geológica.

Para atender ao objetivo proposto, serão tratados especificamente os seguintes temas:

- cálculo e associação de incerteza a distintas fases de pesquisa mineral a partir da elaboração de modelos equiprováveis;
- geração de índices e parâmetros de avaliação de incertezas;
- sumarização dos custos necessários ao desenvolvimento da pesquisa geológica referente à etapa de sondagem e desenvolvimento de modelo de teores e tonelagens;
- estabelecimento a correlação entre a redução das incertezas e o volume de investimento financeiro.

CAPITULO 2 – FUNDAMENTAÇÃO TEÓRICA

Neste tópico serão abordados conceitos estatísticos aplicados aos estudos geoestatísticos e fundamentais para a análise dos depósitos minerais. Também será desenvolvida uma breve revisão dos conceitos geoestatísticos utilizados neste trabalho, assim como a introdução aos conceitos de incertezas em meios geológicos, com ênfase nas incertezas associadas à avaliação de recursos minerais.

2.1 REVISÃO DOS CONCEITOS ESTATÍSTICOS

A análise estatística consiste em um conjunto de cálculos de medidas estatísticas que resume as informações de uma determinada população e propiciam a visão global dos dados.

De acordo com Sinclair & Blackwell (2004), o objetivo geral da análise estatística é inferir parâmetros (características) de uma população (depósito mineral) a partir de amostras (análises químicas de amostras de superfície, testemunhos, canal, etc.).

No desenvolvimento dos trabalhos de avaliação de recursos minerais, diversos conceitos da estatística clássica foram incorporados e o conhecimento deles é fundamental para os estudos das variáveis regionalizadas.

2.1.1 Noção de População e Amostra

De acordo com Landim (2003), o termo *população* refere-se ao conjunto de todas repetições possíveis de um fenômeno aleatório, o que significa que a população é um conjunto de medidas referentes a uma propriedade específica de um grupo de objetos e não de um conjunto de objetos. Dentro deste conjunto de medidas, a observação referente a esta população é denominada *amostra*.

Em termos geológicos, população geológica pode ser exemplificada pela espessura de determinado horizonte de minério do depósito alojado em unidade estratigráfica específica ou ainda por determinado conjunto de indivíduos, tal como os teores de Zn de determinado tipo de rocha em depósito polimetálico.

Como a descrição total da população é praticamente impossível, suas características são inferidas a partir de análises estatísticas derivadas do conjunto de amostras (Landim, 2003), selecionadas através de um processo de amostragem.

Como destacado por Chieregati (2007), a amostragem é uma sequência de operações que tem por objetivo extrair uma parte significativa, ou amostra, de um determinado universo.

No processo de amostragem, além de definir o procedimento ideal de coleta das amostras (elaboração do plano de amostragem), deve-se levar em consideração os custos e a precisão requerida para tais resultados, visto que estes são elementos diretamente proporcionais e que poderão representar prejuízo considerável ou até mesmo distorção dos resultados que acarretarão sérias consequências técnicas (Trajano, 1963).

Yamamoto & Rocha (2001) destacam que no processo de avaliação mineral, a amostragem é o passo inicial e tem por objetivo a determinação da continuidade do corpo mineralizado, geometria e teores associados, bem como sua distribuição espacial.

Dentre os métodos de amostragem utilizados na avaliação de recursos minerais, podem ser destacados a amostragem aleatória simples, a aleatória estratificada e a sistemática, descritos em Yamamoto & Landim (2013) e resumidos como:

- ***Amostragem Aleatória Simples:*** na amostragem aleatória simples, uma população constituída por N unidades é numerada sequencialmente e cada valor presente nesta unidade será sorteado sem que haja a reposição dos valores. Nos estudos geoestatísticos, as coordenadas geográficas são definidas como componentes aleatórias;
- ***Amostragem Aleatória Estratificada:*** a amostragem é feita a partir de estratos, ou seja, a região será subdividida em células de dimensões fixas e a coleta das amostras será determinada a partir de um ponto aleatório selecionado dentro de cada célula. Isso possibilitará que ao término do processo, o número de unidades selecionadas será igual ao número de células;
- ***Amostragem Sistemática:*** consiste em selecionar as amostras sobre os nós de uma malha regular definida com base em uma origem escolhida aleatoriamente. A definição deste ponto inicial fornece o caráter aleatório desta amostragem, sendo os demais pontos selecionados de forma sistemática.

Comparativamente o método de amostragem sistemática é o que fornece os melhores resultados, porém, por ser um método que demande um maior planejamento para execução, nem sempre é possível obedecer aos critérios de regularidade, já que a coleta das amostras depende de uma série de fatores externos tais como: acesso, acidentes geográficos, vegetação, etc. (Yamamoto & Landim, 2013).

2.2 As variáveis aleatórias

Conforme pode ser observado em Journal (1989), uma variável aleatória corresponde a uma variável (Z) que assume diferentes valores ou realizações ($z_i, i = 1, \dots, N$) com determinada probabilidade de ocorrência.

Comumente as variáveis aleatórias são representadas por letras maiúsculas ($Z, X, Y, etc.$) e os valores específicos dessas variáveis por letras minúsculas (Journal, 1989; Deutsch & Journal, 1998; Yamamoto & Landim, 2013).

As variáveis aleatórias podem ser subdivididas em contínuas e discretas (Stevens, 1946 *apud* Yamamoto & Landim, 2013). Quando um número de ocorrências de uma variável aleatória é finito, as variáveis aleatórias são consideradas discretas. Se o número de possibilidades for infinito, a variável aleatória é denominada contínua.

Em uma relação direta com a geologia, as variáveis aleatórias discretas podem ser definidas por denominações ou categorização, como por exemplo, tipo de litologia, estrutura da rocha, grau de alteração hidrotermal dos depósitos, etc.

Já as variáveis aleatórias contínuas são medidas de escala relacional ou intervalar, ou seja, os valores das variáveis aleatórias contínuas não podem ser listados e representam dados em escala de intervalo, como por exemplo, número de fraturas em um intervalo de sondagem rotativa (RQD), dados de densidade aparente em determinado tipo de minério, dados de teores em um testemunho de sondagem, etc. (Yamamoto & Landim, 2013).

2.2.1 Características das variáveis aleatórias

Para a interpretação de distintas variáveis aleatórias são utilizadas medidas numéricas que, além de sintetizar as informações das variáveis, analisam como os valores tendem a se comportar em relação aos valores médios desta população.

Dentre estas medidas, as mais utilizadas são as de tendência central: média, moda e mediana e, as medidas de dispersão: variância, desvio padrão e coeficiente de variação.

- A **média** (μ) é uma medida de tendência central equivalente à soma dos valores de todas as observações (x_i) dividido pelo número de observações n (Landim, 2003):

$$\mu = \bar{X} = \frac{\sum x_i}{n}$$

O valor médio das variáveis aleatórias também pode ser designado “esperança matemática” sendo comumente $\bar{X} = E(x)$ (Journel, 1989; Yamamoto *et al.*, 2001).

Se considerarmos uma distribuição de frequência teórica de uma variável aleatória contínua, onde a população é infinita, o parâmetro poderá ser obtido através da fórmula (Landim, 2003):

$$\mu = E(x) = \int_{-\infty}^{+\infty} x_i f(x) dx$$

- A **moda** de uma população corresponde ao valor ou a classe de valores que ocorre com maior frequência em um conjunto de dados (Correa, 2003). Se todos os valores forem diferentes entre si, não existe moda, porém, um mesmo conjunto de dados poderá apresentar mais de uma moda: bimodal, trimodal ou multimodal.
- A **mediana** corresponde ao valor da variável aleatória a 50% da distribuição acumulada de frequências (Yamamoto, 2001). A mediana é uma medida robusta, pois não é afetada pelos valores extremos como a média.
- A **variância (σ^2)** corresponde à dispersão em torno da média. Para obter os valores desta dispersão calcula-se uma medida de variação segundo o desvio médio (Landim, 2003):

$$DM = \frac{\sum(x_i - \mu)}{n}$$

Porém, como destacado por Landim (2003), esta fórmula tende a sempre fornecer resultado igual a 0, sendo necessário elevar os termos ao quadrado:

$$\sigma^2 = \frac{\sum(x_i - \mu)^2}{n}$$

Para uma distribuição teórica de uma variável, n torna-se indeterminado (infinito), sendo a variância calculada por (Landim, 2003):

$$\sigma^2 = \int_{-\infty}^{\infty} (x_i - \mu)^2 f(x) dx$$

O **desvio padrão** das variáveis será simplesmente a raiz quadrada da variância, sendo expresso na mesma unidade dos valores originais:

$$\sigma = \sqrt{\sigma^2}$$

- O **coeficiente de variação** é uma relação entre o desvio padrão e a média que fornece uma medida relativa de variabilidade das observações para posições negativas ou positivas (Landim, 2003).

$$CV = \frac{\sigma}{\mu}$$

Yamamoto *et al.* (2001) enfatizam que, por ser uma medida adimensional, o CV é amplamente utilizado na comparação relativa dos valores em torno da média principalmente para comparação e classificação de depósitos minerais segundo a variabilidade natural.

2.3 Distribuição de frequências

Geralmente, quando se faz a análise das variáveis aleatórias, a função $f(x)$ que descreverá o comportamento da variável é desconhecida e, para que essas variáveis possam ser descritas matematicamente, o uso de distribuições de frequências teóricas facilita a compreensão de um grande volume de informações e permite a manipulação matemática dos valores das variáveis aleatórias a fim de desenvolver métodos estatísticos (Landim, 2003).

Para o caso de variáveis aleatórias contínuas aplicadas à geologia, teremos dois principais tipos de distribuição: distribuição normal e distribuição lognormal (Landim, 2003).

2.3.1 Distribuição Normal ou Gaussiana

Conforme destacado por Correa (2003), a distribuição normal ou gaussiana é o modelo mais importante na estatística e foi deduzido pelo matemático alemão Carl Gauss (1777 – 1855) como a probabilidade dos erros de observação, sendo inicialmente denominada como a “lei normal dos erros”.

O modelo de distribuição normal é caracterizado por dois parâmetros, a média μ e a variância σ^2 , sendo a função de densidade de probabilidade dada por:

$$f(X) = \frac{1}{\sigma\sqrt{2\pi}} e^{-1/2\left[\frac{(X-m)}{\sigma}\right]^2}$$

Onde m é a posição central da distribuição (média, m) e σ a dispersão da distribuição (desvio padrão, σ). A Figura 2.1 ilustra uma curva normal típica com parâmetros de média e desvio padrão descrito:

Figura 2.1 – Curva normal típica (modificado de Correa, 2003)

Mesmo que a distribuição normal seja apenas uma distribuição teórica, a maioria das distribuições segue uma distribuição normal ou aproximadamente normal, conforme mencionado por Yamamoto *et al.* (2001), sendo exemplos em geologia dados oriundos de cotas topográficas, porosidade de arenitos, etc. (Landim, 2003).

2.3.2 Distribuição Lognormal

A distribuição lognormal de uma variável contínua é aquela em que o logaritmo das variáveis apresenta uma distribuição normal (Koch & Link, 1971). Este tipo de distribuição é comumente encontrado representando teores de metais raros, como, por exemplo, ouro, platinóides, prata, etc., onde há grande quantidade de teores baixos e poucos valores de teores altos.

A função cumulativa de densidade de probabilidade desta distribuição é dada por:

$$f(X) = \frac{1}{X \beta \sqrt{2\pi}} e^{-1/2\left[\frac{(\log X - \alpha)}{\beta}\right]^2}$$

onde α corresponde à média dos logaritmos de X e β é o desvio padrão dos logaritmos de Y em relação a α .

Como observado por Journal (1989), a função de distribuição lognormal $f(X)$ sempre será assimétrica positiva, com uma longa cauda à direita, permitindo a ocorrência de muitos valores, porém, com probabilidade de ocorrência cada vez menor. A Figura 2.2 demonstra uma curva lognormal típica:

Figura 2.2 – Função de densidade de probabilidade (fdp) lognormal (modificado de Journal, 1989)

2.4 REPRESENTAÇÕES GRÁFICAS

A representação gráfica de uma variável é útil pela rapidez e consistência ao se transmitir informações sobre um conjunto de dados.

Diversos gráficos são utilizados para visualizar as estatísticas descritivas das variáveis, sendo os mais utilizados: o Box Plot e o Histograma.

- Os gráficos do tipo **Box Plot** têm por objetivo analisar a variação de uma variável entre distintos grupos de dados. Neste tipo de gráfico três itens são de extrema importância para a visualização dos dados, dispersão e assimetria da distribuição: o valor mínimo (LI), os quartis (Q1, Md e Q3), e o valor máximo (LS) conforme apresentado na Figura 2.3. A distancia entre quartis (DQ) ou distância interquartis conterà 50% da distribuição dos dados e realçará informações importantes acerca dos dados, como por exemplo, variabilidade e simetria.

Figura 2.3 – Esquema de construção do Box Plot

- O **Histograma** (Figura 2.4) é um gráfico de barras justapostas em que a base de cada uma delas corresponde ao intervalo de classe e sua altura equivale à respectiva frequência. A partir deste gráfico são realizadas as análises de distribuição de frequências e este também refletirá a variabilidade natural dos depósitos (Yamamoto *et al.*, 2001).

Figura 2.4 – Histograma para dados da variável U

2.5 REVISÃO DOS CONCEITOS GEOESTATÍSTICOS

A geoestatística, de acordo com Olea (1991), consiste na aplicação dos métodos estatísticos nas ciências da Terra, particularmente em geologia. De forma mais específica, a geoestatística envolve o estudo de problemas relacionado às variáveis regionalizadas, termo proposto, segundo Huijbregts (1975), por Matheron em 1965, após diversos trabalhos desenvolvidos por D. Krige e H. Sichel que buscavam soluções à estimativa de teores em minas de ouro da África do Sul.

Como mencionado por Landim (2003), as variáveis regionalizadas são variáveis distribuídas no espaço que apresentam aparente continuidade e são representadas por funções numéricas ordinárias que assumem um valor determinado e variam de um lugar para o outro, descrevendo um fenômeno natural.

Segundo Andriotti (1989), o termo Variável Regionalizada foi escolhido por Matheron com o objetivo de alertar para dois aspectos: o aleatório, no sentido de que as medições podem variar consideravelmente entre si, e o estruturado, segundo uma certa lei no espaço que, de acordo com Isaaks & Srivastava (1989), mesmo não sendo possível estabelecer com exatidão os valores de uma variável regionalizada, as amostras mais próximas no tempo e no espaço tendem a ser mais similares entre si do que as que estiverem distantes.

Com isso, a regionalização das variáveis reflete o caráter estruturado dos fenômenos aleatórios que podem assumir uma série de resultados a partir de uma determinada distribuição de probabilidades (Deutsch & Journel, 1992).

Ainda segundo Deutsch & Journel (1992), as variáveis regionalizadas podem assumir uma gama de valores de acordo com uma distribuição de probabilidade. A variável aleatória é comumente representada por letras maiúsculas (X, Y, Z, etc.) e seus valores específicos são representados por letras minúsculas, seguidas dos índices relativos à cada observação (Deutsch & Journel, 1992).

As variáveis regionalizadas apresentam algumas características que, além das descritas como sendo relacionadas à localização e aleatoriedade, incluem a chamada hipótese intrínseca que, segundo Yamamoto (2001), implica que uma função descreve o comportamento espacial da variável regionalizada dentro do espaço e esta função, por sua vez, é intrínseca da regionalização. Esta função nada mais é do que o variograma e que, na prática, demonstra que a distribuição das diferenças entre dois pontos amostrais é a mesma para todo o depósito e que ela está relacionada apenas à distância e orientação destes os pontos (Yamamoto, 2001).

2.5.1 Função Variograma

Ferramenta fundamental para a geoestatística, a função variograma ou simplesmente variograma, permite descrever quantitativamente a variabilidade das variáveis regionalizadas no espaço e assume a premissa da hipótese intrínseca.

Neste sentido, o gráfico da variância espacial *versus* a distância h representado pelo variograma permite obter a estimativa do valor de variância para as diferentes combinações de pares de pontos e, assim, analisar o grau de dependência espacial da variável estudada, definindo os parâmetros necessários para a estimativa de suas características em locais não amostrados (Souza, 2007).

A função variograma $2\gamma(h)$ é definida como a esperança matemática do quadrado da diferença entre os valores de pontos no espaço, separados por uma distância h (Yamamoto, 2001):

$$2\gamma(h) = E\{[Z(x+h) - Z(x)]^2\}$$

Ou, em linguagem computacional:

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

onde $2\gamma(h)$ é a função variograma, N é o número de pares de pontos separados por uma distância h , $Z(x)$ é o valor da variável regionalizada no ponto x e $Z(x+h)$ é o valor da variável regionalizada no ponto $(x+h)$.

Baseado na estatística clássica, podemos definir a média e a variância de uma variável regionalizada a partir das relações (Yamamoto, 2001):

$$E\{Z(x)\} = m, \forall x \in A$$

$$Var[Z(x)] = E\{[Z(x) - m]^2\}, \forall x \in A$$

Com base na hipótese intrínseca, para um mesmo espaço amostral representado por uma função aleatória, a média será constante e não dependerá dos valores de x e a covariância

existente entre as variáveis (x e $x + h$) dependerá apenas da distância h entre eles, sendo que para uma distância nula ($h = 0$), a covariância será igual à variância (Deutsch & Journel, 1998):

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

Como a média da variável regionalizada x é equivalente à média da variável $x + h$, teremos:

$$\begin{aligned} 2\gamma(h) &= E\{[Z(x) - Z(x + h)]^2\} \\ &= E\{Z(x)^2 - 2[Z(x)Z(x + h)] + E[Z(x + h)^2]\} \\ &= \underbrace{E\{Z(x)^2 - m^2\}}_{\sigma^2} - \underbrace{2[Z(x)Z(x + h)] - m^2}_{C(h)} + \underbrace{E\{Z(x + h)^2 - m^2\}}_{\sigma^2} \\ 2\gamma(h) &= 2\sigma^2 - 2C(h) \\ \gamma(h) &= \sigma^2 - C(h) \end{aligned}$$

onde $\gamma(h)$ é a função semi-variograma, σ^2 corresponde à variância e $C(h)$ equivale à covariância entre os pontos. O termo semi-variograma é empregado quando se considera metade da função variograma, como demonstrado em Journel (1989).

A função semi-variograma $\gamma(h)$ representa o inverso da função covariância, ou seja, quanto maiores os valores da função semi-variograma (variância entre os pontos), menor será a covariância entre eles, como pode ser observado na Figura 2.5.

Figura 2.5 – Relação entre a função variograma e a função covariância (modificado de Olea, 1994)

Segundo Yamamoto (2001), o variograma é determinado segundo uma direção predefinida, sendo considerado, então, uma função vetorial. O mais comum é calcular distintas possibilidades de passos e direções, com o objetivo de conhecer a estrutura do depósito. Na Figura 2.6 apresenta-se uma forma usual de plotagem do semi-variograma experimental calculado para 2 direções.

Figura 2.6 – Semi-variograma experimental para 2 direções

2.5.1.1 Propriedades do variograma

A forma usual de apresentação de um variograma, ou semi-variograma, é feita a partir de um gráfico cartesiano onde a variância espacial $\gamma(h)$ é plotada no eixo das ordenadas e a distância h (euclidiana) no eixo das abscissas.

Os principais aspectos observados em um variograma são facilmente identificados na Figura 2.7 e são descritos como (Yamamoto, 2001):

Figura 2.7 – Representação de um variograma típico com patamar e suas propriedades. (Yamamoto, 2001)

- **patamar:** corresponde ao valor da variância na qual o variograma se estabiliza, é a soma do efeito pepita e da variância espacial;
- **amplitude:** é a distância em que as amostras passam a ser espacialmente independentes entre si, ou seja, à distância que separa o campo estruturado (distância até onde as amostras são espacialmente correlacionadas) do campo aleatório (região onde as amostras são independentes);
- **efeito pepita:** é o valor da função variograma próximo à origem. Este fenômeno é comumente associado a microestruturas geológicas, erros de amostragem ou inadequação na escala de amostragem;
- **variância espacial:** corresponde à diferença entre o patamar e o efeito pepita.

2.5.2 Principais modelos teóricos de variograma

Após calculados os variogramas experimentais, é necessário o ajuste de uma função denominada modelo teórico de variograma. Esta etapa é fundamental na análise variográfica e demanda, além de conhecimento e experiência, diversas tentativas até o ajuste adequado do modelo teórico ao variograma experimental (Landim, 2003).

Existem diversas técnicas de ajuste dos modelos teóricos, podendo ser feitas de forma automática ou manual. Comumente o ajuste automático se dá simultaneamente à geração dos pontos do variograma experimental e, na maioria das vezes, não fornece um ajuste perfeito

entre a função e os pontos, sendo necessária a intervenção manual para a obtenção de resultados satisfatórios.

Como mencionado por Olea (1999), existem infinitas possibilidades de funções de ajuste, mas na prática, pode-se reduzir as possibilidades a apenas algumas. Segundo Isaaks & Srivastava (1989), os principais modelos podem ser agrupados em duas categorias: os que alcançam um patamar, ou modelos de transição e os que não alcançam um patamar.

No primeiro grupo podemos incluir os tipos mais comuns utilizados, como no caso dos modelos esférico, exponencial e gaussiano, já no segundo grupo estão os que recebem incrementos à medida que a distância de sua origem aumenta, sem alcançar um patamar definido.

- **Modelo Esférico:** modelo mais comum encontrado em depósitos minerais. Este modelo é considerado por Olea (1999) como um modelo transitivo, pois apresenta patamar e alcances finito. A função que representa este modelo é dada por:

$$\gamma(h) = C_0 + C \left[\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], \forall h < a$$

$$\gamma(h) = C_0 + C, \forall h \geq a$$

- **Modelo Exponencial:** o modelo aproxima-se do patamar de forma assíntota e seu alcance pode ser representado pela distância h onde o semi-variograma é $0.95C$, ou seja, o alcance prático deverá corresponder à 95% do patamar (Olea,1999):

$$\gamma(h) = C_0 + C \left[1 - \exp\left(-\frac{h}{a}\right) \right]$$

- **Modelo Gaussiano:** apresenta uma curva parabólica junto a origem que implica na pequena variabilidade em pequenas escalas. Assim como o modelo exponencial, a aproximação ao patamar é feita de forma assíntota e na prática, será atingido a 95% do patamar (Olea,1999):

$$\gamma(h) = C_0 + C \left[1 - \exp\left(-\frac{h^2}{a^2}\right) \right]$$

Figura 2.8 – Exemplos de modelos de variograma (Goovaerts ,1997)

Em todos os modelos, C_0 representa o efeito pepita e este representará uma série de variabilidades oriundas de diversas etapas do processo de avaliação (Pitard, 1993; Chilès & Delfiner, 1999):

- variância aleatória gerada em locais com mínimas distâncias (efeito pepita *in situ*);
- variabilidade introduzida através de diferentes fontes e que são inerentes ao processo de amostragem;
- variabilidade introduzida por contaminação, perdas, alterações das propriedades físicas e químicas e erro humano;
- variabilidade introduzida pelos procedimentos analíticos; e
- erros de medida e localização.

Para casos onde se observa a total falta de correlação espacial entre os dados, a análise variográfica não se aplica, sendo comum a observação de um modelo efeito pepita puro (Yamamoto & Landim, 2013).

2.6 MÉTODOS DE ESTIMATIVA

Os métodos de estimativa são por definição procedimentos matemáticos que ajustam uma função para determinados pontos de dados para assim se poder estimar o valor de uma variável em um ponto não amostrado (Yamamoto, 1998).

Segundo Chilès & Delfiner (2012) um dos problemas centrais da geoestatística consiste na estimativa de uma variável de interesse em um domínio baseada em um número restrito de valores observados.

Como mencionado por Landim (2003), estas questões impulsionariam o engenheiro de minas Daniel G. Krige e o estatístico H. S. Sichel, no final da década de 1950, a estudar novas possibilidades de se estabelecer algoritmos de regressão por mínimos quadrados para cálculo de reservas minerais que fornecessem medidas de desvio, sendo que estes trabalhos posteriormente serviriam de base para o desenvolvimento da geoestatística pelo matemático e engenheiro G. Matheron (Rivoiard, 2005).

De modo geral, a técnica desenvolvida para estimativa dos valores desconhecidos passava a considerar as características espaciais de autocorrelação entre as variáveis envolvidas, possibilitando ainda, a inserção de um erro associado a esta estimativa, fato este que até então, não era possível diante os demais algoritmos existentes (Landim, 2003).

A técnica de *Krigagem*, termo cunhado em homenagem à Daniel G. Krige, segundo Yamamoto & Landim (2013), é definida como um processo geoestatístico de estimativa de valores de variáveis distribuídas no espaço e tempo, com base em valores próximos quando considerados interdependentes pela análise variográfica.

De acordo com Landim (2003), a krigagem poderá ser utilizada como algoritmo estimador para:

- prever valores pontuais de variáveis regionalizadas em determinado local dentro do campo geométrico;
- cálculo médio da variável regionalizada para um volume maior que o suporte geométrico, a exemplo do cálculo do teor médio de uma jazida a partir de amostras oriundas de testemunhos de sondagem.

Em todos os algoritmos de krigagem o estimador $Z^*(x_0)$ é baseado no princípio de combinação linear dos dados existentes, definido como (Yamamoto, 2001):

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

Onde λ_i representa os ponderadores obtidos através da resolução de um sistema de equações lineares desenvolvido na krigagem.

Considerando os diversos algoritmos empregados na krigagem, a diferença entre eles consiste no modelo considerado para o cálculo do valor da média $m(x)$, conforme exemplificado por Goovaerts (1999):

- na krigagem simples (KS) o valor médio $m(x)$ é conhecido e constante para todo o domínio:

$$m(x) = m, \text{ conhecida } \forall x \in A$$

- a krigagem ordinária (KO) considera uma flutuação local da média limitada pelo domínio de estacionaridade da média dada uma determinada vizinhança $W(x)$:

$$m(x') = \text{constante mas desconhecida } \forall x' \in W(x)$$

Os mais difundidos e que serão descritos neste trabalho são os algoritmos de krigagem simples e krigagem ordinária. A descrição dos demais algoritmos poderá ser encontrada nos trabalhos de Isaaks & Srivastava, 1989, Goovaerts, 1997, Yamamoto & Landim, 2013, Rossi & Deutsch, 2014.

2.6.1 Krigagem simples (KS)

Todos os algoritmos da krigagem são elaborados com base em uma regressão linear que corresponde ao estimador (Deutsch & Journel, 1992):

$$[Z_{KS}^*(x) - m(x)] = \sum_{i=1}^n \lambda_i(x) [Z(x_i) - m_i]$$

onde $Z(x)$ é a variável aleatória na localização x , x_i corresponde às n localidades, $m(x) = E[Z(x)]$ equivale ao valor esperado da variável aleatória $Z(x)$ e Z_{KS}^* é o estimador da regressão linear da krigagem simples. Os pesos da KS, $\lambda_i, i = 1, \dots, n$ são determinados a partir de (Deutsch & Journel, 1992):

$$\sum_{j=1}^n \lambda_j(x) C(x_j, x_i) = C(x, x_i), i = 1, \dots, n$$

Para o desenvolvimento da krigagem simples um dos requisitos é o conhecimento prévio do valor médio ($m(x) = E[Z(x)]$) em todos os locais do domínio e também o conhecimento da matriz de covariância ($C(x_i, x_j), i, j = 0, 1, \dots, n$). Mediante estes requisitos, a inferência da média e da covariância dos dados requer a hipótese de estacionaridade da função aleatória $Z(x)$. Se a função aleatória assume caráter estacionário, o estimador da krigagem simples pode ser reduzido a:

$$\begin{aligned} Z_{KS}^*(x_0) &= \sum_{i=1}^n \lambda_i [z(x_i) - m_i] + m \\ &= \sum_{i=1}^n \lambda_i z(x_i) + \left[1 - \sum_{i=1}^n \lambda_i(x_i) \right] m \end{aligned}$$

onde $z(x_i)$ corresponde aos dados, m equivale à média conhecida e estacionária e λ_i corresponde aos pesos determinados sobre a condição de minimização e não enviesamento do erro da variância, $\sigma_E^2(x) = Var\{Z_{KS}^*(x) - Z(x)\}$, com sistema da krigagem simples representado por:

$$\sum_{j=1}^n \lambda_j(x) C(x_j - x_i) = C(x - x_i), i = 1, \dots, n$$

Neste sistema, de acordo com Deutsch & Journel (1992), o valor da covariância $C(h)$ não pode ser substituída pelos valores do semi-variograma ($\gamma(h) = C_0 - C(h)$) a menos que a soma dos pesos seja equivalente a um.

A determinação dos pesos da krigagem simples estará apenas atrelado à minimização do erro da variância a partir das derivadas parciais deste erro, conforme descrito por Rossi & Deutsch (2014):

$$\frac{\delta \sigma_E^2}{\delta \lambda_i} = 2 \times \sum_{i=1}^n \lambda_\beta C(u_i, u_j) - 2 \times C(u, u_i) = 0, i = 1, \dots, n$$

2.6.2 Krigagem Ordinária (KO)

A estimativa pela krigagem ordinária em um ponto não amostrado x_i , de acordo com Yamamoto & Landim (2013), é obtida como a combinação linear dos vizinhos próximos e pode ser representada por:

$$Z_{KO}^*(x_0) = \sum_{i=1}^n \lambda_i [Z(x_i)]$$

onde Z_{KO}^* é o valor estimado no ponto (x_0); $z(x_i)$ é o valor da variável regionalizada no i -ésimo ponto e λ_i é o peso correspondente calculado a partir da resolução do sistema de krigagem ordinária.

A KO diferencia-se da KS por não necessitar do conhecimento prévio da média para que os pesos sejam determinados de modo a minimizar a variância do erro na estimativa.

Esta é a essência da krigagem ordinária, que assume que a variância da krigagem é minimizada através da condição da soma dos pesos da krigagem ser equivalente a um (Rossi & Deutsch, 2014):

$$\sum_{i=1}^n \lambda_i = 1$$

Assim como os demais algoritmos de krigagem, a krigagem ordinária tem como característica a precisão local das estimativas em detrimento da precisão global (Journel *et al.*, 2000), por isto, os valores estimados não reproduzem adequadamente nem o histograma nem o variograma dos dados, ambos apresentarão variâncias menores.

2.7 MÉTODOS DE SIMULAÇÃO ESTOCÁSTICA

A simulação é um conjunto de técnicas que consiste na geração de diversos modelos não determinísticos equiprováveis que refletem a variabilidade espacial do domínio, ou seja, reproduz as principais características estatísticas e de correlação de determinado conjunto de dados. Este método foi desenvolvido a partir de ideias elaboradas por Matheron (1973) sobre métodos de simulação por bandas rotativas (*turning bands*).

Deutsch & Journel (1992) definem o processo de simulação estocástica como sendo um método de construção alternativa de modelos equiprováveis de alta resolução de uma distribuição espacial $Z(x)$, onde cada realização será denominada l : $\{z^{(l)}(x), x \in A\}$. Ainda de acordo com estes autores, a simulação se diferencia dos demais algoritmos de interpolação basicamente em dois aspectos:

1. Em diversos algoritmos de interpolação, incluindo a krigagem, o principal objetivo é determinar o melhor e único valor para um ponto não amostrado, sem a preocupação de reproduzir as estatísticas espaciais dos valores estimados como um todo. Na simulação, todas as características espaciais (textura) e estatísticas (histograma, covariância) são predominantes em detrimento da precisão local. Na krigagem, obtém-se um conjunto de dados estimados $z^*(x), x \in A$, onde prevalece a precisão local. Já na simulação, os resultados obtidos fornecem representação global, $z^{(l)}(x), x \in A$, onde a reprodução da variabilidade global prevalecerá.
2. A krigagem, exceto se um modelo gaussiano para o erro for assumido, fornecerá apenas uma medida incompleta da precisão, não permitindo a avaliação precisa da variabilidade quando diversos pontos estimados são considerados. A simulação foi desenvolvida especificamente para possibilitar a avaliação deste tipo de variabilidade conjunta.

Em termos de variância, Journel (1974) destaca que a simulação, quando considerada um estimador, fornece uma variância duas vezes maior que a krigagem, porém, estimar o valor preciso de um ponto em uma determinada localidade não é o objetivo da simulação. A simulação tem como principal objetivo fornecer valores equiprováveis para uma mesma localidade, honrando principalmente a relação de continuidade e distribuição das amostras.

Como descrito no item 2.6 o algoritmo da krigagem busca minimizar a variância do erro. A decorrência disto é que valores considerados abaixo da média, tendem a ser superestimados e, valores acima da média, tenderão a ser subestimados (Goovaerts, 1999). Deutsch & Journel (1992) e Olea (1999) associam este grau de “suavização” à configuração e à densidade dos dados originais, ou seja, quanto maior a quantidade de dados menor será a suavização.

Na simulação condicional, o efeito de suavização tende a ser corrigido (Deutsch & Journel, 1992), possibilitando a correta reprodução do modelo de variabilidade espacial das

amostras, independentemente da configuração espacial ou densidade dos dados. Com isso, espera-se que, além de honrar os valores nos pontos amostrados os modelos simulados reproduzam as mesmas características de dispersão dos dados originais (histograma e variograma).

Para a construção de modelos simulados, é possível o uso de inúmeros algoritmos, e para a escolha do método mais adequado, deve-se levar em consideração o tipo de depósito, a função de transferência (RF) que será utilizada, a quantidade e a qualidade da informação a ser utilizada, os requisitos computacionais e o modelo de saída desejado (Deutsch & Journel, 1998; Myers, 1996; Rossi & Deutsch, 2014).

Existem métodos específicos para variáveis contínuas e categóricas, assim como métodos com abordagem gaussianas ou não gaussianas. A descrição detalhada dos distintos métodos de simulação e suas principais características podem ser encontradas em Chilès & Delfiner (2012), Pyrcz & Deutsch (2014), Rossi & Deutsch (2014).

Para o desenvolvimento deste trabalho foi escolhido o método de Simulação Sequencial Gaussiana (SGS) que é um dos métodos de simulação mais difundidos no meio da mineração.

2.7.1 Simulação Sequencial Condicional

Segundo Journel & Kyriakidis (2000), a simulação é dita condicional se as realizações resultantes em pontos que coincidam com pontos amostrais forem iguais aos valores amostrais:

$$z^{(l)}(x_i) = z(x), \forall l \text{ se } x_i = x$$

Onde $z(x_i)$, representa o valor do atributo $Z(x)$, observado na localização x_i e $z^{(l)}(x_i)$ é a l -ésima realização de Z naquela posição.

De acordo com Journel (1974), a simulação condicional atende a três requisitos básicos:

- reproduzir o histograma dos dados disponíveis;
- reproduzir a variabilidade espacial das amostras através da reprodução do variograma;
- honrar os valores dos dados em suas localidades, sendo então, condicionais.

A simulação sequencial condicional tem como objetivo obter valores correlacionados a uma função distribuição de densidade obtida inicialmente a partir dos dados originais $z(x_i)$,

e que posteriormente agregará as realizações precedentes a esta função (Chilès & Delfiner, 1999). Na prática, a seleção dos dados $z^{(l)}(x)$ é feita a partir de um caminho aleatório, sendo cada localização x_i selecionada apenas uma vez.

De acordo com Dimitrakopoulos (1998), todos os métodos sequenciais de simulação seguem o mesmo algoritmo, diferenciando-se apenas em relação às funções aleatórias utilizadas. A sequência realizada a partir destes algoritmos é:

- i. Dentro de um espaço A, seleciona-se aleatoriamente um bloco, ou nó a ser estimado (cada bloco será selecionado apenas 1 vez);
- ii. Estima-se a distribuição condicional local de probabilidade do bloco selecionado;
- iii. Seleciona-se aleatoriamente o valor da distribuição estimada;
- iv. Inclui-se o valor obtido na simulação no banco de dados original;
- v. Retorna-se aos itens (i) a (iv) até que todos os blocos sejam simulados;
- vi. Repete-se os passos (i) a (v) gerando múltiplos modelos equiprováveis.

2.7.2 Simulação Sequencial Gaussiana (SGS)

Segundo Olea (1999), a simulação sequencial gaussiana é um método que gera realizações parciais utilizando funções aleatórias normais multivariadas.

Para que qualquer tipo de função aleatória possa ser aplicado na SGS, é necessário que se faça a transformação dos dados utilizando uma função gaussiana multivariada e estacionária. Segundo Deutsch & Journel (1998), a função $Z(x) = \{Y(x), x \in A\}$ será uma função multivariada gaussiana se e somente se:

- os subconjuntos da função aleatória (RF) também forem gaussianos;
- todas as combinação lineares das variáveis aleatórias forem gaussianas;
- as distribuições condicionais de uma variável aleatória, determinadas por outras variáveis aleatórias que forem simuladas, forem normais.

Como na natureza raramente encontram-se modelos com distribuição gaussiana, para a utilização deste método é usual realizar a transformação dos dados para a obtenção do modelo Gaussiano, onde:

$$Prob\{Y(x) \leq y\} = G(y), \forall y$$

com, $G(y)$ igual à função cdf padrão Gaussiana; $Y(x)$ é função aleatória da distribuição da variável original padronizada $N(0, 1)$.

Além da condição de gaussianidade para o subconjunto das funções aleatórias, todas as combinações lineares desta componente aleatória de $Y(x)$ também deverão apresentar uma distribuição normal, sendo assim:

$$X = \sum_{\alpha=1}^n \omega_{\alpha} Y(x_{\alpha}) \quad \forall \omega_{\alpha}, \text{ desde que } x_{\alpha} \in A$$

Uma vez cumprida essas premissas, a função aleatória $Z(x)$ pode ser simulada por meio de simulação sequencial gaussiana e deverá proceder da seguinte forma (Deutsch & Journal, 1998):

- i. Determina-se a função densidade acumulada (cdf – *cumulative density function*) univariada $F_z(z)$ representativa de todo o domínio e não apenas dos dados amostrais z disponíveis.
- ii. Utilizando-se a $F_z(z)$ faz-se a transformação normal dos dados para $Y(x)$.
- iii. Verifica-se a bigaussianidade dos dados normais transformados através da verificação dos valores experimentais da cdf separados pelo vetor h ; isto poderá ser feito através de distintos procedimentos de verificação.
- iv. Caso o modelo gaussiano possa ser adotado para a função aleatória da variável transformada (y), prossegue-se com a simulação sequencial:
  - Define-se um caminho aleatório para a sequência de simulação dos nós da malha;
  - Inicia-se no nó (x_0) da sequência definida, para o qual são escolhidos os (n) pontos mais próximos, incluindo-se os dados amostrados e os dados previamente simulados. A partir disto faz-se a estimativa dos valores em (x_0) através da krigagem simples, onde o valor estimado $y_{KS}^*(x_0) = \sum_{i=1}^n \lambda_i y(x_i)$ será a média condicional e a variância da krigagem simples $\sigma_{KS}^2(x_0) = C(0) - \sum_{i=1}^n \lambda_i C(x_i - x_0)$ representará a variância condicional;

- Determina-se a função de distribuição acumulada condicional (fdac) em (x_0) e extrai-se $y^l(x_0)$ aleatoriamente. Como mencionado por Yamamoto & Landim (2013), isto equivale a adicionar um resíduo aleatório na estimativa $y_{KS}^*(x_0)$, conforme relação: $Z_{sim}^l(x_0) = Z^*(x_0) + R^l(x_0)$, onde $R^l(x_0)$ é uma variável aleatória da l -ésima realização correspondente ao erro da estimativa;
  - Adiciona-se o valor simulado previamente ao conjunto de dados;
  - Repete-se o algoritmo para o próximo nó (x_0) até que todos os nós da malha sejam visitados.
- v. Faz-se a transformação inversa dos valores normais simulados conforme $\{z^{(l)}(x) = \Phi^{-1}(y^{(l)}(x), x \in A)\}$.

2.7.2.1 Transformação Gaussiana

Como já mencionado, a abordagem de caráter gaussiano é condicionada à distribuições exclusivamente gaussianas, o que implica que todos os dados sejam representados pelo seu valor médio (m) e desvio padrão (σ) através da função de densidade de probabilidade:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x-m)^2}{2\sigma^2}\right] \quad -\infty < x < \infty$$

Existem diversas formas relativamente simples para transformar a função aleatória $F_Z(z)$ em uma função normal $F_Y(y)$, sendo suas variáveis aleatórias Z e Y , respectivamente.

O método mais simples faz a correspondência gráfica direta através da transformação quantil-quantil, onde a função de distribuição acumulada (cdf) de cada variável (original e normal) é utilizada para realizar a transformação. A este método denominamos *normal score* (NS) e a representação gráfica desta transformação encontra-se na Figura 2.9 que representa a seguinte relação:

$$y = G^{-1}(F(z)) \text{ com função reversa } z = F^{-1}(G(y))$$

Figura 2.9 – Transformação gaussiana a partir de função de distribuição acumulada (Rossi & Deutsch, 2014)

Esta transformação é realizada com a ordenação dos dados amostrais z de forma crescente, sendo computada a frequência de distribuição acumulada com ordenamento k para que ocorra a transformação normal z^k correspondente ao k/n quantil de uma função de densidade acumulada normal:

$$y(z) = G^{-1}(F(z)) = G^{-1}(p_k^*)$$

De acordo com Rossi & Deutsch (2014) este método apresenta uma desvantagem em relação a outros pois o ordenamento dos números pode gerar sequências difíceis de serem interpretadas e, por ser um processo não linear, os parâmetros da distribuição não podem ser transformados diretamente através da função reversa, sendo necessário um ajuste dos dados previamente à transformação.

Um outro método, que será utilizado neste trabalho, consta da transformação a partir de uma função matemática chamada anamorfose gaussiana (ϕ) (Isatis®). Esta função é definida por uma expansão polinomial que necessita ser ajustada aos dados. Uma vez ajustada, a função transforma a Z em uma variável gaussiana Y e vice-versa (Neufeld, 2005):

$$z(x) = \Phi(y(x)) \approx \sum_{n=0}^{np} \Phi_n H_n[y(x)]$$

onde, np é o maior termo do polinômio de expansão, Φ_n corresponde ao coeficiente de ajuste de cada termo dos polinômio e $H_n[y(x)]$ é o polinômio de Hermite, definido pelo termo de expansão e os valores de y .

Figura 2.10 – Exemplo de ajuste da função anamorfose (Neufeld, 2005)

2.7.2.2 Verificação da multigaussianidade (binormalidade)

Apenas normalizar os dados através dos métodos apresentados não assegura que o modelo da função aleatória seja normal. A transformação através dos métodos *normal score* ou de anamorfose garante apenas a normalidade da distribuição de probabilidade local, sendo necessário, ainda, validar a transformação para os demais estados da distribuição.

A verificação de dois pontos em uma distribuição é relativamente simples, checar três pontos ou mais já se torna um processo muito mais complexo, portanto na prática, faz-se a verificação entre dois pontos e, caso seja assumida a hipótese de bi-Gaussianidade, assume-se a multi-Gaussianidade para toda a distribuição (Rossi & Deutsch, 2014).

Para realizar o teste de hipótese entre dois pontos, pode-se optar por verificar se a distribuição da combinação linear entre pares de pontos transformados $Y(x)$ e $Y(x+h)$, $\forall x, \forall h$ também é normal (Deutsch & Journel, 1998).

Uma outra forma de verificação considera a relação entre o madograma $\gamma_1(h)$ e o variograma $\gamma_2(h)$ que deverá ser próximo a:

$$\frac{\gamma_1(h)}{\sqrt{\gamma_2(h)}} = \frac{1}{\sqrt{\pi}} = 0,564$$

onde, $\gamma_1(h) = E\{[Z(x+h) - Z(x)]^2\}$ e $\gamma_2(h) = E\{[Z(x+h) - Z(x)]\}$.

Esta validação pode ser feita graficamente, conforme gráfico da Figura 2.11. Observa-se no gráfico que os valores para distintos passos ocorrem muito próximos à constante, 0,564.

Figura 2.11 – Teste de binormalidade. Razão madograma/variograma de uma base de dados fictícia

2.8 INCERTEZAS NA ESTIMATIVA DE RECURSOS

A análise de incertezas em recursos minerais é tema bastante recorrente em diversos trabalhos geoestatísticos (Goovaerts, 1997; Journel & Huijbregts, 1978; Isaaks & Srivastava, 1989; Pilger, 2000; Souza, 2007; Arroio Ortiz, 2008; entre outros) mas, embora a incerteza dos modelos de recursos seja algo intrínseco diretamente envolvidos aos riscos do empreendimento mineiro, a quantificação e manejo desta informação é pouco difundida no ambiente corporativo e operacional.

Comumente, quando falamos em modelo de recursos, este é apresentado na forma de modelo de blocos georeferenciado, contendo os teores médios estimados, informações de densidade, volume, tipo de material (pode ser litologia ou classe de teor) e metal contido. Raramente costuma-se inserir neste modelo a informação de incerteza, seja ela oriunda da estimativa dos teores ou da definição do volume dos blocos para cada material avaliado.

Neste contexto, a incerteza poderia ser inserida como uma medida de dispersão ao redor do valor estimado, indicativa da magnitude do erro associado a este número, uma vez que a determinação exata do erro desta variável estimada é inviável, pois, para isso, seria necessário o conhecimento do valor real em cada posição desconhecida (Isaaks & Srivastava, 1989).

De acordo com Rozman (1998), absolutamente todos os modelos de recursos são equivocados, sendo uns menos que os outros. Muitos fatores influenciam nesta afirmação e no grau de incerteza associado aos processos de estimativa, por isso, independente dos procedimentos ou melhores práticas adotadas, sempre será possível associar alguma incerteza ao modelo final apresentado.

De acordo com Mann (1993) existem 3 tipos de incertezas e diversas fontes associadas a elas:

- Tipo I: incertezas associadas a erros de medida, viés e imprecisão dos processos de medida;
- Tipo II: incerteza inerente às variações naturais devido à diferentes propriedades físicas em distintas regiões espaciais;
- Tipo III: incerteza ocasionada pela falta de informação ou ignorância científica.

Os dois primeiros tipos de incertezas são caracterizados quantitativamente e podem ser minimizadas a partir de diversos processos de validação e calibragem de equipamentos utilizados. Já a incerteza do Tipo III, também chamada por Mann (1993) de “incerteza qualitativa”, por ser tratada de forma subjetiva, requer a conscientização maior das consequências ocasionadas pela falta de informação, o que por muitas vezes, só pode ser notado a partir da geração de vários modelos que permitam a estimativa do grau de incertezas associado.

Mann (1993) destaca, ainda, que a geoestatística fornece medidas de incerteza às variáveis regionalizadas através do uso de medidas de dispersão (variância da krigagem) e cálculos de variogramas, permitindo o acesso respectivamente aos Tipos I e II, assim como o acesso ao Tipo III associado diretamente ao espaçamento das informações amostrais.

No âmbito da estimativa dos recursos minerais, além de considerarmos esses tipos de incerteza descritos, podemos ainda incluir outros fatores qualitativos que devem ser levados em consideração e que apresentam impacto significativo nas incertezas do modelo de recursos e reservas, conforme descrito por Morley *et al.* (2003):

- definição do corpo de minério;
- interpretação geológica;
- estimativa de recurso;
- estimativa de reserva mineral e planejamento de mina.

Em cada uma destas etapas pode-se detalhar diversas fontes de incertezas, sendo as mais críticas relacionadas aos procedimentos de amostragem, falhas na interpretação do modelo tridimensional e escolha e aplicação incorreta dos métodos de estimativa adotados.

Na etapa de estimativa, em que se obtém os dados de tonelagem e teor, os níveis de incertezas relacionados à estimativa dos teores dependerão da decisão em relação ao modelo matemático assumido (Morley *et al.*, 2003).

Nos tópicos seguintes serão detalhadas as principais medidas de incertezas relacionadas à estimativa dos recursos, considerando apenas as variáveis que dependem exclusivamente dos métodos geoestatísticos. Para avaliação de outras fontes de incertezas citadas, podem-se consultar trabalhos de diversos autores, como Isaak & Srivastava (1989); Pitard (1993); Goovaerts (1997); Noppé (2004); Chierigati (2007); Souza (2007), entre outros.

2.8.1 Métodos utilizados na avaliação das incertezas

Em Goovaerts (1997) é apresentada uma discussão sobre a modelagem das incertezas sobre o desconhecido com objetivo de acessar os riscos envolvidos em processos de tomada de decisão. Esses modelos de incertezas, além de contribuírem para esta etapa de decisão, permitem estabelecer diferentes estimativas ótimas com base em distintos critérios, sendo cada uma adaptada a determinado cenário.

Considerando o problema de modelagem da incerteza sobre dois valores desconhecidos $z(x_1)$ e $z(x_2)$, como realizações de duas funções aleatórias espacialmente dependentes $Z(x_1)$ e $Z(x_2)$ respectivamente, o acesso às incertezas locais nestas duas localidades será possível de duas maneiras (Goovaerts, 1997):

- através da minimização da variância do erro (krigagem) estimado e derivação dos correspondentes intervalos de confiança arbitrariamente definidos como Gaussianos e;
- através do modelo de distribuição local de probabilidade das duas variáveis aleatórias $Z(x_1)$ e $Z(x_2)$.

2.8.1.1 A variância de krigagem

A krigagem, por definição, é um estimador linear que fornece os melhores valores médios não enviesados, a partir da minimização da variância do erro. A partir disto, teremos que a variância de krigagem, medida que reflete do erro associado à estimativa, será fornecida pelo arranjo espacial:

$$\sigma_{ko}^2 = C(0) - \sum_i \lambda_i \text{Cov}\{Z(x_i), Z(x_0)\} - m$$

onde λ_i são os pesos ponderados da krigagem ordinária e m o valor médio da krigagem ordinária.

Segundo Goovaerts (1997), a abordagem tradicional de modelagem da incerteza em local não amostrado, consiste na minimização da variância do erro associada $\sigma_{E(x_0)}^2 = \text{Var}\{Z^*(x_0) - Z(x_0)\} = 0$. A estimativa dos valores e o erro da variância são comumente combinados e derivados a um intervalo de confiança do tipo Gaussiano centrado no valor estimado, conforme relação:

$$\text{Prob}\{Z(x_0) \in [z^*(x_0) - 2\sigma_E(x_0), z^*(x_0) + 2\sigma_E(x_0)]\} = IC$$

onde $\sigma_{E(x_0)}^2$ é a variância do erro de krigagem e IC o valor do intervalo de confiança definido entre 0 e 1.

Apesar de ser um método simples, que necessita apenas de uma medida de correlação entre os valores de z , representado pelo variograma ou função de covariância, a modelagem do erro exige duas hipóteses restritas (Goovaerts, 1997):

- i. A estimativa do erro deverá ser modelada como a realização do erro da variável aleatória Gaussiana. Esta exigência leva assumir que a distribuição local dos erros assume caráter simétrico, o que na prática, gera superestimava de valores baixos e subestimativa de valores altos, ou seja, efeito de suavização.
- ii. A variância do erro será independente dos valores dos dados, dependendo apenas da configuração espacial dos mesmos, uma vez que em sua formulação, não considera os valores das amostras em si, apenas a covariância que é calculada em função da configuração espacial dos dados, em situação referida como homoscedasticidade.

Esta premissa implica que, para um mesmo variograma, a variância de krigagem da estimativa poderá ser similar em condições onde os valores locais variam de alto a baixo, desde que a configuração dos dados seja a mesma.

Portanto, a σ_E^2 não pode ser utilizada diretamente como uma medida de dispersão dos valores estimados, podendo apenas ser interpretada como um indicativo da possível magnitude dos erros (Goovaerts, 1997).

2.8.1.2 Variância de interpolação

Yamamoto (2000) propôs uma alternativa para a representação da incerteza local da estimativa através do cálculo da variância de interpolação que, ao contrário da variância de krigagem, depende diretamente dos valores dos pontos amostrais. Desta forma, a variância de interpolação é calculada segundo:

$$S_0^2 = \sum_{i=1}^n \lambda_i [z(x_i) - z_{ko}^*(x_0)]^2$$

onde z_{ko}^* é o valor estimado no ponto (x_0) ; $z(x_i)$ é o valor da variável aleatória no i -ésimo ponto e λ_i são os pesos ponderados da krigagem ordinária.

De acordo com Yamamoto (2000), a variância de interpolação apresenta as seguintes características:

- garante a exatidão da krigagem, pois, em um valor amostrado, a variância de interpolação será igual a zero;
- aumenta proporcionalmente à dispersão dos valores próximos utilizados na interpolação;
- utiliza indiretamente a distância estrutural do variograma por meio dos pesos da krigagem ordinária.

Exposto isso, a variância de interpolação parece ser uma solução alternativa para determinação das incertezas relacionadas à estimativa por krigagem ordinária (Yamamoto & Landim, 2013), uma vez que reproduz a variabilidade local honrando os dados amostrados e considera o modelo de variabilidade espacial das amostras.

2.8.2 Distribuição local de probabilidade

No âmbito geológico, comumente representamos os fenômenos através de funções randômicas, as quais são definidas como um conjunto de variáveis aleatórias localizadas no espaço e que apresentam interdependência através de mecanismos probabilísticos (Isaaks & Srivastava, 1989).

Estas variáveis, descritas pelos mesmos autores, podem assumir diversos resultados ou realizações e são geradas de forma aleatória a partir de um mecanismo probabilístico. Uma vez gerado este conjunto de resultados e suas respectivas probabilidades, denominamos distribuição de probabilidade randômica ou, lei de probabilidade.

Caso esta distribuição seja conhecida, é possível inferir diversos parâmetros que descrevem as características estatísticas de interesse da variável.

Conforme exposto no item 2.8.1, Goovaerts (1997) discute, além dos métodos de minimização da variância do erro em valores estimados, métodos mais rigorosos e que avaliam as incertezas sobre locais desconhecidos, a partir de intervalos de probabilidade independentes de qualquer estimativa $z^*(x_0)$ a partir do valor desconhecido $z(x_0)$.

Seja a função de distribuição de probabilidade $F(x; z|(n) = Prob\{Z(x) \leq z|(n)\})$ condicionada à informação (n) disponível em sua totalidade, os intervalos de probabilidade podem ser derivados de:

$$Prob\{Z(x) \in (a, b)|(n)\} = F(x; b|(n)) - F(x; a|(n))$$

Cada uma das funções de probabilidade condicionada $F(x_0; z|(n))$ fornece uma medida de incerteza local, já que em sua fórmula, depende diretamente da localização específica x_0 .

2.8.2.1 Variância condicional

A variância condicional mede o espalhamento da curva em função da distribuição condicional relacionada ao seu valor médio e é representada por:

$$\sigma^2(x) = \sum_{k=1}^{k+1} [\bar{Z}_k - Z_E^*(x)]^2 \times [F(x; Z_{k-1})]$$

onde:

- Z_k , $k = 1, \dots, K$, são K valores de limiares (*threshold*) discretizando o intervalo de variação dos z -valores;
- $\bar{Z}_k$ corresponde à média da classe (Z_{k-1}, Z_k) ;
- $Z_E^*(x)$ é o valor esperado da função de distribuição condicional (cdf) aproximado por uma soma discreta;
- $F(x; Z)$ é a função de valores dos teores de Z para uma determinada localização x

A variância condicional definirá o espalhamento em torno da média e este, por sua vez, é dependente da média das classes $\bar{Z}_k$. Esta média e as classes extremas da cdf são bastante sensíveis à definição do modelo de extrapolação da distribuição (Goovaerts, 1997) por isso, é necessário atentar-se ao uso desta medida frente a um determinado modelo de extrapolação da função de distribuição condicional.

2.8.2.2 Coeficiente de variação condicional (CV)

Segundo Pilger (2000), o coeficiente de variação condicional é um método mais robusto que, embora apresente a mesma característica em relação à escolha do modelo de interpolação, é expresso em função da média, filtrando, assim, o efeito proporcional. O cálculo deste parâmetro é dado então por:

$$CV = \frac{\sqrt{\sigma^2(x)}}{Z_E^*(x)} = \frac{\sqrt{\sum_{k=1}^{k+1} [\bar{Z}_k - Z_E^*(x)]^2 \times [F(x; Z_{k-1})]}}{\sum_{k=1}^{k+1} \bar{Z}_k \times [F(x; z_k|(n) - F(x; z_{k-1})|(n))]}$$

Driedrich (2012) cita que com este índice é possível verificar o grau de representatividade da média relativo ao conjunto de dados, sendo muito útil para a comparação da variabilidade em grupos de dados com ordem de magnitude e unidades de medidas distintos. Normalmente, quanto maiores os valores deste coeficiente, maior é a dispersão associada à estimativa da média.

2.8.2.3 Intervalo entre quartil condicional (IEQ)

O intervalo entre quartis condicional é definido como a diferença entre o quartil superior $q_{0.75}$ e o quartil inferior $q_{0.25}$ da distribuição:

$$IEQ(x) = q_{0.75}(x) - q_{0.25}(x)$$

Como mencionado por Dierich (2012), esta medida, por ser mais robusta que as demais, é indicada principalmente para a avaliação de medidas de espalhamento local de distribuições assimétricas, já que não considera os valores extremos. De acordo com Goovaerts (1997), o contraste entre áreas de variabilidade alta e áreas de variabilidade baixa fica mais saliente quando utilizado o intervalo entre quartis.

CAPITULO 3 – MATERIAIS E MÉTODOS UTILIZADOS

A definição da metodologia empregada neste projeto foi compatível com os objetivos iniciais de avaliar as incertezas de um modelo de recursos em distintas fases, representadas aqui por campanhas de sondagem. Para isto, dados de pesquisa e exploração (sondagem rotativa) oriundos de um depósito de cobre, localizado no Complexo de Mineração Sossego serão utilizados e, posteriormente, simulações geoestatísticas servirão de base para uma análise probabilística das incertezas.

O método de simulação geoestatística foi o escolhido por permitir calcular tanto informações acerca dos teores quanto das incertezas associadas a eles. De acordo com Rossi & Deutsch (2014) os modelos de simulação proveem a mesma informação de um modelo estimado através de métodos convencionais (krigagem), porém, preservam a variabilidade original dos dados, o que resulta na manutenção dos valores extremos observados na distribuição e também, reproduzem o histograma e a variabilidade espacial dos dados, conforme demonstrado na Figura 3.1.

Figura 3.1 – Comparação entre modelo estimado e modelo simulado (Deutsch & Rossi, 2014)

3.1 BASE DE DADOS

Para o desenvolvimento do trabalho proposto foi necessário uma base de dados sólida e que apresentasse o histórico de pelo menos alguns anos de pesquisa, com informações de teor e geologia. Inicialmente seriam necessários dados de interpretação geológica (sólidos em 3D) para cada campanha de sondagem realizada, porém, foi disponibilizada apenas uma interpretação geológica, desenvolvida a partir dos dados mais recentes (2003) e que foi adotada como representativa da subdivisão geológica de todas as campanhas de sondagem.

3.1.1 Contexto geológico da área de estudo

Os dados disponibilizados inserem-se no contexto do Complexo de Mineração Sossego, um importante depósito de cobre localizado no sudeste do estado do Pará, na região norte do Brasil. O depósito de Sossego, atualmente operado pela companhia Vale S.A., é constituído por dois grupos de corpos mineralizados que apresentam associações de alteração hidrotermal distintas, conforme descrito por Monteiro *et al.* (2008) e demonstrado na Figura 3.2.

A mineralização do depósito é representada pela associação de calcopirita com pirita, siegenita, millerita, vaesita, ouro, Pd-melonita e, subordinadamente, hesita, cassiterita, esfarelita, galena e molibdenita (Moreto, 2010). Esta mineralização associa-se a brechas hidrotermais as quais no depósito Sequeirinho, segundo Monteiro *et al.* (2008a, b), apresentam predominância de calcopirita e ocorrem de forma tardia, em condições essencialmente rúpteis. Já no depósito Sossego, as brechas apresentam fragmentos da rocha hospedeira hidrotermalizada que ocorrem envolvidos por magnetita e em sua matriz, apresentam calcopirita, carbonatos e quartzo.

Figura 3.2 – (A) Mapa geológico simplificado da região do Complexo de Mineração Sossego (modificado de VALE por Monteiro *et al.*, 2008); (B) Distribuição esquemática das zonas de alteração hidrotermais na Mina Sossego (Monteiro *et al.*, 2008a)

Os dados utilizados para o estudo são oriundos exclusivamente da cava Sequeirinho, cuja mineralização é estruturalmente controlada por veios calcopiríticos que penetram fraturas hidráulicas de brechas hidrotermais e também ocorre de forma disseminada. A Figura 3.3 apresenta uma seção esquemática que demonstra as principais zonas hidrotermais e rochas hospedeiras.

Figura 3.3 – Seção esquemática do corpo Sequeirinho com destaque às zonas de alteração hidrotermais. Modificada de Monteiro *et al.*, 2008a

3.1.2 Banco de dados

O banco de dados disponibilizado contém as informações básicas conforme:

- Planilha *Header*: coordenadas X (Leste), Y (Norte) e Z (cota) da boca dos furos de sondagem e ano de execução do furo (Campanha);
- Planilha *Survey*: medidas profundidade (Até), azimuth (BRG) e dip (DIP) ao longo do furo;
- Planilha *Assay*: informações de profundidade (De-Até) e teores de Cu (%). Ressalta-se que os valores de teor são modificados através de uma constante para preservação do sigilo dos dados originais.

Ao todo foram disponibilizados 298 furos de sondagem totalizando mais de 11.3071,74 metros lineares de testemunho.

Para o desenvolvimento desta pesquisa foram utilizados apenas 257 furos realizados em campanhas de 1997 a 2003. Os demais furos não utilizados foram descartados pois a localização dos mesmos estavam fora do alvo de interesse. A Figura 3.4 mostra a proporção de furos realizados por ano e sua localização em 2D pode ser vista na Figura 3.5.

Figura 3.4 – Proporção de número de sondagem rotativa por campanha

Figura 3.5 – Mapa em 2D da localização das distintas campanhas de sondagem

3.1.3 Topografia

O mapa topográfico disponibilizado é composto por curvas de nível espaçadas de 1 em 1 metro no sistema de coordenadas UTM-SAD69. Para desenvolvimento dos trabalhos foi desenvolvido um modelo digital de terreno a partir da interpolação das curvas do mapa topográfico.

Este modelo digital de terreno serviu como limite superior para o modelo de blocos. Na Figura 3.6 apresenta-se o modelo digital de terreno e a localização dos furos de sondagem utilizados nesta pesquisa.

Figura 3.6 – Topografia 3D da área em estudo indicando localização dos furos e unidades geológicas (Datamine Studio 3D®)

3.1.4 Modelo de Blocos

O modelo de blocos apresenta dimensões de 10 metros nos eixos X e Y e 16 metros no eixo Z. Essas definições foram atribuídas com base no modelo geológico definido e nas necessidades de planejamento de longo prazo do depósito. O modelo de blocos está ortogonal

ao eixo Norte-Sul e não contém sub-blocos. A Figura 3.7 apresenta uma seção esquemática típica do modelo de blocos.

Figura 3.7 – Seção vertical esquemática (S-N) do modelo de blocos 2D com definição da geologia local

O modelo disponibilizado contém informações de geologia local e estas informações foram utilizadas como base para a subdivisão do banco de dados de acordo com os litotipos encontrados. A partir disto, a base de dados completa foi classificada de acordo com a litologia em um processo conhecido como *backflag* e, posteriormente, subdividida de acordo com a campanha de sondagem.

A Tabela 3.1 elenca os litotipos descritos no modelo de blocos e considerados para a subdivisão dos dados de sondagem.

Tabela 3.1 – Lista de litotipos considerados na subdivisão dos dados

CODIGO	COR	DESCRIÇÃO
1		OXIDADO MALAQUITICO
2		OXIDADO SAPROLITICO
4		SULFETO DISSEMINADO
5		MISTO LIXIVIAÇÃO
6		MISTO FLOTAÇÃO
10		BRECHA SULFETADA

3.2 PREMISSAS ADOTADAS

Para o desenvolvimento do trabalho tiveram de ser adotadas algumas premissas, conforme os item que seguem:

- O banco de dados que será utilizado encontra-se delimitado pelo modelo de blocos;
- A geologia do depósito foi considerada única, ou seja, os dados disponibilizados acerca da litologia, presentes no modelo de blocos, foram utilizados para subdivisão dos domínios de todas as campanhas de sondagem. Quaisquer incertezas associadas à interpretação e delimitação dos sólidos de geologia não serão consideradas;
- O modelo estimado através de krigagem ordinária servirá de base para comparação dos valores obtidos nas simulações;
- A subdivisão por campanhas de sondagem sempre considera o acumulado dos furos realizados até o ano selecionado, por exemplo, a campanha de 2000 incluirá os furos de 2000 e também os furos realizados nas campanhas anteriores (1999, 1998 e 1997);
- As litologias descritas como Oxidado Malaquítico e Oxidado Saprolítico não foram consideradas neste estudo, pois se tratam de camadas de cobertura;
- Os custos apresentados neste trabalho foram levantados a partir de uma pesquisa de mercado realizada em distintos depósitos e períodos. Estes custos, definidos como investimentos de pesquisa, não consideram absolutamente todos os gastos com os quais necessariamente um investidor deverá arcar, porém, incluem os gastos mínimos necessários para o desenvolvimento de uma campanha de sondagem rotativa na área de interesse.

3.3 METODOLOGIA PROPOSTA

A proposta desta dissertação considera as melhores práticas encontradas na mineração para a avaliação de recursos minerais e propõe a inclusão dos dados de incertezas ao longo de distintos períodos de pesquisa geológica no modelo final. Para isto as principais etapas envolvidas serão:

- i. Compilação dos dados existentes em distintas fases de pesquisa. Nesta etapa, deve-se considerar os períodos de investimento que cada investidor julgue necessário;
- ii. Estimativa do modelo de recursos com o banco de dados completo por krigagem ordinária. Esta estimativa deverá ser validada de acordo com as melhores práticas e apresentar os melhores valores locais para cada bloco;
- iii. Simulação da variável de interesse para o modelo final, considerando todos os dados e, também, simulação do modelo considerando cada campanha de sondagem separadamente com a finalidade de determinar as flutuações das incertezas ao longo dos anos.

O fluxograma apresentado na Figura 3.8 descreve, de maneira resumida, o procedimento empregado neste trabalho.

Figura 3.8 – Fluxograma de atividades da pesquisa

CAPITULO 4 – RESULTADOS E DISCUSSÃO

4.1 VALIDAÇÃO DA BASE DE DADOS

O banco de dados disponibilizado pela empresa Vale S.A. é oriundo de um depósito mineralizado a cobre, em região de intensa atividade estrutural. De forma geral, a mineralização ocorre associada a veios calcopirítricos, podendo, também, ocorrer de forma disseminada ao longo da rocha hospedeira.

Com este breve contexto em mente, fez-se a validação dos dados litológicos apresentados no modelo de blocos, sendo predominante a ocorrência da litologia disseminada (Sulfeto Disseminado), normalmente associada a baixos teores e, em menor quantidade, a litologia brechada (Brecha Sulfetada) que apresenta teores mais elevados. A Figura 4.1 apresenta a distribuição das litologias Sulfeto Disseminado e Brecha Sulfetada no modelo de blocos utilizado.

Figura 4.1 – Mapa de distribuição de litologias no modelo de blocos

Os demais dados disponibilizados foram validados quanto à:

- a) **Planilha Header:** profundidade final dos furos e compatibilidade com demais planilhas, localização dos dados em relação ao modelo de blocos. Neste caso, todos os furos que se encontravam fora do modelo foram desconsiderados;
- b) **Planilha Survey:** validação do comprimento dos furos na tabela e verificação dos intervalos quanto à direção e mergulho. Todos os furos utilizados estavam de acordo com os padrões;
- c) **Planilha Assay:** validação dos limites de campo numérico (amostras analisadas abaixo do limite de detecção e intervalos analisados compatíveis), validação dos intervalos amostrados (presença de dados duplicados, amostras com intervalos sobrepostos – *overlaps*).

Em todas as planilhas analisadas, não foi encontrada nenhuma incoerência que inviabilizasse o desenvolvimento da pesquisa, portanto, após validação, todas as informações foram importadas para o software Datamine Studio 3® e compiladas em uma única planilha denominada *drillholes*. Esta planilha, posteriormente, servirá de base para definição das amostras regularizadas e separação dos dados por campanha.

4.2 ANÁLISE EXPLORATÓRIA DOS DADOS

Uma vez agrupadas as planilhas, os dados foram subdivididos de acordo com a litologia e campanha. Os intervalos amostrados foram analisados visando caracterizar as estatísticas descritivas da variável Cu (%).

4.2.1 Dados brutos (*Raw Data*)

Para a análise estatística dos dados originais foram consideradas todas as amostras que foram classificadas a partir do modelo de blocos e, a partir de então, subdivididas de acordo com a campanha. Ao todo foram geradas 57.682 amostras, incluindo as amostras referentes às litologias consideradas estéril.

A estatística básica para as amostras referentes às litologias mineralizadas, desconsiderando aquelas abaixo do limite de detecção ($\text{Cu} < 0,01\%$), é apresentada na Tabela

4.1. Os histogramas referentes à distribuição dos dados originais são apresentados no Anexo A.

Tabela 4.1 – Estatística descritiva dos dados originais. Apenas litologias mineralizadas

Campanhas Pré-1998

Litologia	Amostras	Mínimo	Máximo	Média	Variância	Desvio Padrão	Coefficiente de Variação
Sulfeto Disseminado	3,961	0.01	39.08	0.59	1.32	1.15	0.51
Misto Lixiviação	-	-	-	-	-	-	-
Misto Flotação	50	0.01	7.56	0.97	2.23	1.49	0.65
Brecha Sulfetada	1,109	0.01	17.76	2.52	7.08	2.66	0.95

Campanha 1999

Litologia	Amostras	Mínimo	Máximo	Média	Variância	Desvio Padrão	Coefficiente de Variação
Sulfeto Disseminado	7,964	0.01	39.08	0.55	1.34	1.16	0.48
Misto Lixiviação	4	0.64	1.30	0.93	0.05	0.23	4.13
Misto Flotação	134	0.01	7.56	0.63	1.02	1.01	0.62
Brecha Sulfetada	2,140	0.01	24.24	2.34	6.39	2.53	0.92

Campanha 2000

Litologia	Amostras	Mínimo	Máximo	Média	Variância	Desvio Padrão	Coefficiente de Variação
Sulfeto Disseminado	16,236	0.01	39.08	0.53	1.15	1.07	0.49
Misto Lixiviação	14	0.07	7.27	0.98	1.84	1.36	0.72
Misto Flotação	288	0.01	7.56	0.71	1.04	1.02	0.70
Brecha Sulfetada	4,446	0.01	36.00	2.32	7.10	2.66	0.87

Campanha 2002

Litologia	Amostras	Mínimo	Máximo	Média	Variância	Desvio Padrão	Coefficiente de Variação
Sulfeto Disseminado	18,081	0.01	39.08	0.53	1.11	1.05	0.50
Misto Lixiviação	14	0.07	7.27	0.98	1.84	1.36	0.72
Misto Flotação	347	0.01	8.64	0.75	1.27	1.13	0.66
Brecha Sulfetada	5,442	0.01	36.00	2.31	6.61	2.57	0.90

Campanha 2003

Litologia	Amostras	Mínimo	Máximo	Média	Variância	Desvio Padrão	Coefficiente de Variação
Sulfeto Disseminado	20,268	0.01	39.08	0.53	1.13	1.06	0.50
Misto Lixiviação	14	0.07	7.27	0.98	1.84	1.36	0.72
Misto Flotação	363	0.01	8.64	0.73	1.19	1.09	0.67
Brecha Sulfetada	6,180	0.01	36.00	2.27	6.41	2.53	0.90

Ainda foram elaborados gráficos de probabilidade (p-plot) para a verificação de ocorrência de valores extremos. Apesar de existirem valores considerados *outliers*, ou seja, valores extremos anômalos que se desviam da distribuição de cada domínio, por não serem significativamente discrepantes, optou-se por não aplicar nenhum tipo de limite de teores (*capping*).

Na Figura 4.2 são apresentados os gráficos referentes à campanha de 2003, e os demais gráficos de probabilidade referentes às outras campanhas são encontrados no Anexo B.

Figura 4.2 – Gráfico de distribuição de probabilidade dos dados originais (*p-plot*) para campanha 2003

4.2.1 Dados regularizados (*Composite Data*)

O intervalo mineralizado do depósito contém amostras frequentemente apresentando 1 metro de espessura, conforme demonstrado no histograma da Figura 4.3.

Como este comprimento é o mais frequente, realizou-se a regularização dos dados em compostas de 1 metro, respeitando os limites da litologia. Após a regularização, obteve-se o total de 30.661 amostras.

Figura 4.3 – Histograma de distribuição das espessuras das amostras originais

4.2.2 Análise dos dados

Após a regularização dos dados, realizou-se a análise dos distintos grupos litológicos com o intuito de distinguir diferentes domínios. Para tanto, fez-se a análise dos grupos litológicos utilizando recursos gráficos como *boxplots* e análise de contato.

Os resultados obtidos permitiram diferenciar claramente duas populações: uma de alto teor (*high grade*), representada pela litologia Brecha Sulfetada e outra de baixo teor (*low grade*), representada pelo Sulfeto Disseminado. Outras duas litologias, Misto Lixiviação e Misto Flotação, apresentaram valores baixos de teor de Cu (%), contudo, na análise de contato, não demonstraram muita afinidade com a litologia disseminada, sendo então tratadas de forma distinta, porém, agrupadas, já que a quantidade de informações existentes para as duas litologias é insuficiente para a análise geoestatística. Apresenta-se na Figura 4.4 os resultados da análise de contato para os dados da campanha 2003 e na Figura 4.5 os *boxplot* para campanha 2003. Os demais gráficos *boxplot* são apresentados no Anexo C.

Figura 4.4 – Análise de contato entre as principais litologias. Dados da campanha 2003

Figura 4.5 – Boxplot da distribuição de Cu (%) por litologia, campanha 2003

Após avaliação das litologias, definiram-se os domínios que seriam considerados no trabalho. A configuração final destes domínios é apresentada na Tabela 4.2.

Tabela 4.2 – Descrição dos domínios definidos para análise geoestatística.

Litologia	Código	Descrição
Sulfeto Disseminado	4	Baixo Teor - Low Grade
Misto Lixiviação + Misto Flotação	Grupo 1	Teor Intermediário
Brecha Sulfetada	10	Alto Teor - High Grade
Misto Flotação + Brecha Sulfetada	Grupo 2	Alto Teor - High Grade

*Exclusiva da campanha Pré-1998

4.2.3 Análise estatística dos dados regularizados

Com a definição dos domínios geoestatísticos a análise estatística das populações com os dados regularizados foi realizada, assim como o desagrupamento das amostras que, posteriormente, foi utilizado no processo de transformação gaussiana e simulação geoestatística. A descrição estatística da variável Cu (%) para os distintos domínios é apresentada na Tabela 4.3.

Tabela 4.3 – Estatísticas descritivas dos domínios geoestatísticos para as amostras regularizadas e desagrupadas.

Campanhas Pré-1998											
Litologia	Amostras	Mínimo	Máximo	Média	Desvio Desagrupad	Variância	Desvio Padrão	Coefficiente de Variação	Q25	Q50	Q75
Sulfeto Disseminado	4,032	0.01	39.08	0.59	0.58	1.29	1.13	0.52	0.09	0.28	0.67
Brecha Sulfetada	1,098	0.01	17.76	2.52	2.49	6.79	2.61	0.97	0.75	1.60	3.51
Grupo 2	1,148	0.01	17.76	2.45	2.43	6.68	2.58	0.95	0.68	1.56	3.41
Campanha 1999											
Litologia	Amostras	Mínimo	Máximo	Média	Desvio Desagrupad	Variância	Desvio Padrão	Coefficiente de Variação	Q25	Q50	Q75
Sulfeto Disseminado	8,977	0.01	39.08	0.55	0.53	1.28	1.13	0.49	0.09	0.25	0.58
Brecha Sulfetada	2,135	0.01	17.76	2.34	2.25	5.87	2.42	0.97	0.67	1.54	3.15
Grupo 1	146	0.01	7.56	0.65	0.55	0.98	0.99	0.66	0.09	0.30	0.89
Campanha 2000											
Litologia	Amostras	Mínimo	Máximo	Média	Desvio Desagrupad	Variância	Desvio Padrão	Coefficiente de Variação	Q25	Q50	Q75
Sulfeto Disseminado	19,009	0.01	39.08	0.53	0.50	1.06	1.03	1.95	0.10	0.25	0.54
Brecha Sulfetada	4,456	0.01	36.00	2.32	2.26	6.52	2.55	1.10	0.65	1.54	3.06
Grupo 1	328	0.01	7.56	0.73	0.73	0.97	0.99	1.34	0.11	0.36	0.93
Campanha 2002											
Litologia	Amostras	Mínimo	Máximo	Média	Desvio Desagrupad	Variância	Desvio Padrão	Coefficiente de Variação	Q25	Q50	Q75
Sulfeto Disseminado	21,056	0.01	39.08	0.53	0.50	1.03	1.01	1.91	0.09	0.25	0.55
Brecha Sulfetada	5,403	0.01	36.00	2.31	2.30	6.07	2.46	1.07	0.67	1.56	3.08
Grupo 1	374	0.01	8.56	0.76	0.77	1.19	1.09	1.44	0.12	0.38	0.92
Campanha 2003											
Litologia	Amostras	Mínimo	Máximo	Média	Desvio Desagrupad	Variância	Desvio Padrão	Coefficiente de Variação	Q25	Q50	Q75
Sulfeto Disseminado	23,995	0.01	39.08	0.53	0.50	1.04	1.02	1.91	0.09	0.25	0.55
Brecha Sulfetada	6,252	0.01	36.00	2.27	2.28	5.88	2.43	1.07	0.66	1.54	3.02
Grupo 1	414	0.01	8.56	0.74	0.68	1.12	1.06	1.43	0.12	0.37	0.90

Na Figura 4.6 são apresentados os histogramas dos dados regularizados da campanha 2003, separados por domínios. Pode-se observar que todos apresentam assimetria positiva, típico deste tipo de depósito. Os histogramas das demais campanhas podem ser observados no Anexo D.

Figura 4.6 – Histograma para os dados compostos da campanha 2003

4.3 Estimativa do modelo por krigagem ordinária

Para obter os valores ótimos do depósito em estudo, realizou-se a estimativa de blocos através da krigagem ordinária com o banco de dados completo (campanha 2003). Este modelo de blocos estimado servirá de base para a comparação dos índices de incertezas calculados para os demais anos.

Todas as análises variográficas e estimativa foram desenvolvidas no programa Isatis® e foram feitas separadamente de acordo com o domínio geoestatístico definido.

4.3.1 Análise Variográfica

A análise variográfica foi feita para cada domínio interpretado conforme discutido no item 4.2.2. Para cada um dos domínios, realizou-se a verificação da anisotropia através da análise do variograma de superfície (*variogram map*). Os gráficos gerados nesta etapa destacaram que os dados são anisotrópicos e que os eixos da elipse que representa esta anisotropia são compatíveis com a direção e mergulho regional do depósito, exceto para o domínio do Grupo 1 que, aparenta ser isotrópico. Os gráficos relacionados a esta verificação são apresentados no Anexo E.

Os variogramas experimentais foram calculados segundo direções identificadas nos mapas supracitados e, os modelos teóricos ajustados para cada domínio são apresentados nas Figuras 4.7, 4.8 e 4.9. Na Tabela 4.4 apresentam-se os parâmetros de ajuste utilizados.

Tabela 4.4 – Parâmetros do modelo teórico de variograma ajustado para dados da campanha 2003.

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura			Terceira Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	N140°	0.28	0.27	esférico	55	0.175	esférico	70	0.3	esférico	350
	N230°/80°NW				60			150			250
	Plano ortogonal				30			35			50
Brecha Sulfetada	N80°	1.2	4.03	esférico	60	0.45	esférico	95	-	-	-
	N170°/40°NW				95			100			-
	Plano ortogonal				5.5			12.5			-
Grupo 1	Omnidirecional	0.75	0.66	esférico	108	-	-	-			

Figura 4.7 – Modelo teórico ajustado para domínio intermediário – Grupo 1

Figura 4.8 – Modelo teórico ajustado para domínio de baixo teor – Sulfeto Disseminado

Figura 4.9 – Modelo teórico ajustado para domínio de alto teor – Brecha Sulfetada

4.3.2 Parâmetros de estimativa e modelo estimado

Para a estimativa do modelo de teores utilizou-se uma vizinhança móvel e distinta para cada domínio. Os parâmetros de busca foram atrelados aos alcances máximos dos respectivos variogramas, assim como a direção para cada um dos eixos. Os parâmetros de vizinhança utilizados são apresentados na tabela 4.5 e os resultados obtidos são apresentados nos histogramas da Figura 4.10. Na Figura 4.11 é apresentada seção 2D do modelo estimado.

Tabela 4.5 – Parâmetros de vizinhança para estimativa por krigagem ordinária

Elipsóide	Parâmetros de Vizinhança		
	Sulfeto Disseminado	Brecha Sulfetada	Grupo 1
Eixo Maior	220	190	108
Eixo Intermediário	240	125	108
Eixo Menor	104	50	108
Mínimo de amostras	3	3	2
Nº de setores angulares	4	4	4
Máximo de amostras por setor	4	4	4
Nº máximo de setores consecutivos vazios	3	3	-
Nº máximo de amostras por furo	3	4	3
Discretização do bloco	2 x 2 x 2	2 x 2 x 1	2 x 2 x 1

Figura 4.10 – Histograma dos teores de Cu (%) estimados no modelo de blocos

Figura 4.11 – Mapa de teores em 2D dos teores no modelo de blocos

4.3.3 Validação do modelo estimado

Para a validação do modelo estimado realizou-se a comparação entre os teores médios das amostras (Cu_%) e os teores médios estimados (Cu_OK) e, também, realizou-se a validação através de médias locais, denominada análise de deriva. Nesta análise, compara-se a média dos valores obtidos através da krigagem ordinária com a média dos valores obtidos através da estimativa por vizinhos mais próximos (Cu_NN).

Como apresentado na Tabela 4.6, os teores estimados estão próximos aos teores das amostras e, os gráficos de validação de médias móveis da Figura 4.12, demonstram que, para as regiões com bastante amostras, não ocorrem variações significativas nos teores médios do modelo, sendo que os valores obtidos podem ser considerados adequados. No Anexo F são apresentados os gráficos de validação para os demais eixos e campanhas.

Tabela 4.6 – Estatística básica do modelo estimado por krigagem ordinária

Domínio/Litologia	Total de Blocos	Total Estimado	Mínimo	Máximo	Média	Desvio Padrão	Variância	Coefficiente de variação	Q5	Q50	Q75
Sulfeto Disseminado	69,590	68,617	0.013	10.204	0.501	0.464	0.215	0.925	0.103	0.366	0.617
Misto Lixiviação	193	111	0.147	6.331	1.737	1.235	1.526	0.711	0.196	2.002	2.011
Misto Flotação	617	599	0.057	6.349	0.687	0.723	0.523	1.052	0.103	0.502	0.803
Brecha Sulfetada	12,821	12,767	0.035	14.977	2.147	1.22	1.489	0.568	0.722	1.905	2.659
Grupo 1	810	710	0.057	6.349	0.852	0.908	0.825	1.067	0.108	0.578	1.043
Grupo 2	13,438	13,366	0.035	14.977	2.081	1.24	1.537	0.596	0.533	1.855	2.62
Total	83,221	82,094	0.013	14.977	0.76	0.879	0.773	1.157	0.111	0.433	0.9

Figura 4.12 – Análise de deriva para o eixo X para as litologias de Sulfeto Disseminado (*low grade*), Brecha Sulfetada (*high grade*) e Grupo 1

4.4 SIMULAÇÃO SEQUENCIAL GAUSSIANA (SGS)

Para a verificação das incertezas foi realizada a simulação sequencial gaussiana (SGS) dos dados de Cu (%) para os distintos domínios e para cada etapa da pesquisa. Ao todo foram criados 15 modelos simulados. Optou-se por um número de 100 realizações em cada modelo. Como cada um dos domínios apresentava distintas características, foram necessárias a verificação e a validação de cada um individualmente.

4.4.1 Transformação dos dados para distribuição gaussiana (anamorfose)

Para o desenvolvimento da simulação sequencial com algoritmo gaussiano foi necessário realizar a normalização dos dados para que atendessem os pré-requisitos apresentados no item 2.7.2.1.

A transformação gaussiana foi feita através da função anamorfose (ϕ) e, para cada domínio analisado, considerou-se um número distinto de polinômios que melhor se adequava à distribuição original.

A Figura 4.13 ilustra a aderência observada entre a distribuição cumulativa dos dados originais e os dados transformados e também o histograma dos valores originais e valores resultantes do processo de transformação.

No Anexo G são apresentados os gráficos de ajuste da função anamorfose juntamente com os histogramas resultantes do processo de transformação, assim como os histogramas que validam os dados transformados. Conforme esperado, estes últimos histogramas apresentaram uma distribuição Gaussiana com $\mu = 0$ e $\sigma^2 = 1$.

Figura 4.13 – (a) função experimental anamorfose (preto) e modelo expandido da função original em termos do polinômio Hermite (magenta); (b) Histograma dos valores originais de Cu (preto) e valores resultantes do processo de transformação (rosa)

Após realizada a transformação dos dados é necessário validar os resultados para a garantia da hipótese de multigaussianidade. Para atender as premissas demonstradas item 2.7.2.2, foi utilizada a relação variograma²/madograma do programa Isatis®, que deverá ser

constante e próxima a $\sqrt{\pi} = 1.772$. A Figura 4.14 apresenta os gráficos utilizados para a validação da transformação gaussiana. No Anexo H são apresentados os gráficos referentes às demais campanhas.

Figura 4.14 – Teste de binormalidade através da razão variograma²/madograma. Dados campanha 2003

4.4.2 Análise variográfica dos dados transformados

Na Figuras 4.16, 4.17 e 4.18 são apresentados os variogramas experimentais e respectivos modelos teóricos de variogramas ajustados aos dados da campanha 2003 normalizados. Ao todo foram calculados 15 variogramas experimentais, sendo um para cada domínio geoestatístico, separados para cada campanha. Os parâmetros de ajuste dos variogramas são resumidos na Tabela 4.7. Para o cálculo do efeito pepita foram construídos

variogramas ao longo do furo (*down-the-hole*) com passos equivalentes ao comprimento das amostras.

Os variogramas e respectivos modelos ajustados das campanhas 2002, 2000, 1999 e Pré-1998 são apresentados no Anexo I.

Figura 4.15 – Modelo de variograma omnidirecional ajustado para dados do Grupo 1, campanha 2003

Figura 4.16 – Modelo de variograma ajustado nas principais direções anisotrópicas para dados referentes ao domínio Sulfeto Disseminado, campanha 2003

Figura 4.17 – Modelo de variograma ajustado nas principais direções anisotrópicas para o domínio Brecha Sulfetada, campanha 2003

Tabela 4.7 - Parâmetros do modelo teórico de variograma ajustado para dados da campanha 2003

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura			Terceira Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	N140°	0.36	0.524	Esférico	65	0.1	Esférico	300	0.12	Esférico	10000
	N230°/80°NW				125			650			10000
	Plano ortogonal				22			60			60
Brecha Sulfetada	N120°	0.3	0.5	Esférico	180	0.2	Esférico	400	-	-	-
	N210°/50°NW				7			10			-
	Plano ortogonal				80			105			-
Grupo 1	Omnidirecional	0.3	0.68	Exponencial	180	0.11	Exponencial	199	-	-	-

4.4.3 Parâmetros da simulação

Os parâmetros de vizinhança utilizados para simulação dos distintos modelos são apresentados na Tabela 4.8. Os demais parâmetros são apresentados no Anexo J.

Tabela 4.8 - Parâmetros de vizinhança de simulação

Parâmetros - 2003	Parâmetros de vizinhança da simulação		
	Sulfeto Disseminado	Grupo 1	Brecha Sulfetada
Eixo Maior	300	133	400
Eixo Intermediário	125	133	105
Eixo Menor	60	133	10
Nº aleatório (<i>seed</i>)	758,961	245,785	74,180
Mínimo de amostras	3	3	3
Nº de setores angulares	4	4	4
Máximo de amostras por setor	2	2	2
Nº máximo de blocos previamente simulados	4	4	4
Distância mínimo entre duas amostras selecionadas	2	1	1

4.4.4 Validação dos resultados

Para a validação dos resultados, levaram-se em consideração as médias das simulações, os histogramas das realizações, os histogramas das simulações e os respectivos modelos de variabilidade espacial. A Figura 4.18 demonstra o valor médio das 100 simulações comparado ao valor médio obtido através da krigagem ordinária. Os demais litotipos e campanhas são apresentados no Anexo K. Já as Figuras 4.19 e 4.20 apresentam os histogramas obtidos em cenários aleatórios para a variável simulada. Os demais histogramas são apresentados no Anexo L.

Observando-se os resultados apresentados na Figura 4.18 e os contidos no Anexo K, interpreta-se que os valores médios obtidos para cada realização se encontram dispersos ao redor da média dos dados e apresentam boa aderência. Já quando comparamos com os valores médios obtidos na krigagem é possível observar a alternância clara entre cenários com teores elevados e outros com teores baixos em relação aos valores médios das amostras no domínio.

Os histogramas apresentados demonstram clara reprodução da distribuição dos dados, sendo predominantemente lognormal positivo.

Figura 4.18 – Gráficos de validação da média para os valores médios simulados na campanha de 2003

Figura 4.19 - Histogramas de validação domínio Sulfeto Disseminado, campanha 2003

Figura 4.20 - Histogramas de validação para domínio Brecha Sulfetada, campanha 2003

4.4.5 Imagens equiprováveis e intervalos de probabilidade

Para verificação dos resultados finais obtidos na simulação, foram elaborados mapas da distribuição dos teores em 2D e mapas de probabilidade de ocorrência de teores acima de um *cutoff* de 1% de Cu. A evolução dos teores ao longo das distintas campanhas são apresentados nas Figuras 4.21 e 4.22.

Como observado na Figura 4.21, para a mesma perspectiva, observa-se relativo aumento dos teores conforme desenvolvimento de novas campanhas. Nos mapas de probabilidade, assim como no de teores, fica evidente o incremento de teores acima do *cutoff* para os modelos mais recentes (após 2000). Este fato, provavelmente se relaciona ao volume de informações existentes desde a primeira campanha (Pré-1998) até a última campanha considerada (2003), como evidenciado na Figura 4.23.

Figura 4.21 – Mapa de distribuição de teores simulados por campanha

Figura 4.22 – Probabilidade da ocorrência de tores acima do *cutoff* aleatório de 1% Cu

Figura 4.23 – Distribuição de amostras no modelo de blocos por campanha

Nota-se que o detalhamento dos teores em relação à distribuição e ao *cutoff* ocorre logo após o ano de 2000 quando um volume expressivo de sondagens foi desenvolvido. Outro ponto de destaque observado nos mapas de teores refere-se à grande variabilidade de teores existentes no modelo, o que, em termos práticos, nos leva a esperar grandes flutuações ao redor da média e valores de variância global elevados.

4.5 Comparação entre distintos níveis de incertezas

Os índices de incerteza escolhidos para análise dos resultados aqui correspondem à variância condicional, o coeficiente de variação condicional e o intervalo interquartis.

Os resultados que serão apresentados e discutidos correspondem apenas aos litotipos Brecha Sulfetada (alto teor) e Sulfeto Disseminado (baixo teor).

Os resultados resumidos da análise dos índices de incerteza são apresentados na tabela 4.9.

Tabela 4.9 - Parâmetros de incerteza resumidos para os respectivos litotipos simulados em termos de Cu (%).

Dominio	Campanha	1998	1999	2000	2002	2003
Brecha Sulfetada	Mínimo	0.21	0.12	0.10	0.14	0.04
	Média	2.45	2.36	2.28	2.29	2.29
	Máximo	5.90	7.25	12.26	12.10	13.82
	Variância Condicional	6.43	5.69	6.25	6.14	5.25
	Coeficiente de Variação Condicional	1.03	1.01	1.06	1.04	0.97
	Intervalo Interquartis	2.73	2.50	2.25	2.27	2.20
Sulfeto Disseminado	Mínimo	0.02	0.04	0.02	0.02	0.02
	Média	0.59	0.54	0.51	0.51	0.50
	Máximo	2.90	5.14	5.23	6.28	4.85
	Variância Condicional	1.41	1.37	0.94	0.93	0.92
	Coeficiente de Variação Condicional	1.68	1.75	1.56	1.53	1.61
	Intervalo Interquartis	0.59	0.50	0.46	0.45	0.45

Comparando os parâmetros estatísticos das distribuições ao longo das campanhas de sondagem é possível notar redução dos valores em praticamente todos parâmetros observados, sendo o intervalo interquartis aquele que mais evidenciou a redução esperada, quando comparamos as campanhas pré-1998 e 2003, com redução de até 31% para o domínio de alto teor e 24% para o domínio de baixo teor.

4.6 Comparação entre valores médios obtidos por simulação e krigagem ordinária

Conforme resultados médios apresentados na Tabela 4.9, é possível observar que para todos os domínios, houve redução dos valores médios entre as campanhas Pré-1998 e 2003.

A partir dos gráficos de boxplot apresentados nas Figuras 4.25 e 4.26 observa-se que entre as campanhas Pré-1998 e 2000 esta redução foi maior para ambos domínios analisados e para as campanhas 2000, 2002 e 2003 não observaram-se flutuações significativas.

Os gráficos do tipo boxplot, como mencionado nos itens 2.4 e 2.8.2.3, indicam o espalhamento local das distintas distribuições e, como observado nos gráficos subsequentes, nota-se que a variação dos intervalos interquartis é bem mais expressiva no domínio de alto teor, o que reflete o comportamento mais errático e, consequentemente, mais incerto deste tipo de mineralização.

Figura 4.24 – Boxplot dos teores médios de Cu (%) para distintas campanhas de sondagem referentes ao domínio de baixo teor (Sulfeto Disseminado)

Figura 4.25 – Boxplot de teores médios de Cu (%) para distintas campanhas de sondagem referentes ao domínio de alto teor (Brecha Sulfetada)

4.7 Avaliação de custos da pesquisa geológica

Para correlacionar as incertezas ao volume de investimentos necessários foi elaborada planilha de orçamento com base em cotações atuais de diversas atividades necessárias ao desenvolvimento de uma campanha de sondagem. Nos dados apresentados não são considerados todos os gastos que devem ser contabilizados para uma real perspectiva de investimento, são listadas apenas as atividades consideradas vitais à execução dos trabalhos para obtenção de amostras para a elaboração do modelo de recursos.

A planilha apresentada na Figura 4.26 considera apenas uma campanha de sondagem rotativa diamantada em local de fácil acesso e que disponibilizem o mínimo de infraestrutura necessária ao desenvolvimento dos trabalhos. No exemplo apresentado, são considerados apenas 2 equipamentos de sondagem que apresentam produção média mensal de aproximadamente 600 metros perfurados com recuperação superior a 90% do intervalo.

Os custos fixos apresentados correspondem a gastos relacionados a uma equipe local de 6 pessoas e que serão responsáveis por todos os trabalhos de descrição de testemunhos, amostragem e preparação das amostras, elaboração de modelos geológicos e estimativa de teores e tonelagens. Conforme a demanda de sondagem aumenta, é necessário o incremento de todos os itens apresentados. Na Tabela 4.10 é demonstrado o sumário dos gastos desembolsados em cada campanha de sondagem.

A Figura 4.27 mostra a relação entre o aumento do número de metros perfurados e o volume total investido. Conforme já constatado nos demais itens, o ano 2000 foi o que mais investiu em pesquisa, com cifras da ordem de R\$ 28,1 milhões, sendo a campanha de 2002 a que teve menor investimento (R\$ 3,1 milhões).

CUSTO FIXO	MÃO DE OBRA	FUNÇÃO	QUANTIDADE	SALÁRIO MENSAL	TOTAL BENEFÍCIOS	CUSTO MENSAL C/ ENCARGOS
		Coordenador de Campo (Geólogo Júnior)*	2	6,700.00	850.00	26,878.00
		Técnico de Mineração*	2	3,000.00	850.00	13,706.00
		Auxiliar de Campo*	2	1,500.00	850.00	8,366.00
		TOTAL	6		2,550.00	48,950.00
	*Tempo integral					
	TOTAL A: SALÁRIOS + BENEFÍCIOS E ENCARGOS SOCIAIS					48,950.00
	INFRAESTRUTURA	DESCRIÇÃO	QUANTIDADE	CONSUMO MÊS	VALOR UNITÁRIO	CUSTO MENSAL
		Locação do imóvel	1	-	1,000.00	1,000.00
		Energia	1	-	500.00	500.00
		Abastecimento de Água	1	-	100.00	100.00
		IPTU	1	-	50.00	50.00
		Internet	1	-	63.90	63.90
		Telefonia	1	-	106.50	106.50
		Manutenção	verba	-	500.00	500.00
		TOTAL	2		2,320.40	2,320.40
		VEÍCULOS	QUANTIDADE	CONSUMO MÊS	VALOR UNITÁRIO	CUSTO MENSAL
		Pick-Up (Cabine Dupla)	2	1.00	3,500.00	7,000.00
		Combustível (litros)	2	150.00	3.50	1,050.00
		Manutenção	2	1.00	1,000.00	2,000.00
		TOTAL	6		4,503.50	10,050.00
	TOTAL B: INFRAESTRUTURA + MANUTENÇÃO					12,370.40
CUSTO VARIÁVEL	SONDAGEM ROTATIVA	DESCRIÇÃO	QUANTIDADE	CONSUMO MÊS	VALOR UNITÁRIO	CUSTO MENSAL
		Desmobilização Equipe*	1	0.08	15,000.00	1,250.00
		Metragem Diâmetro NQ	1	-	500.00	-
		Partição dos testemunhos	1	-	20.00	-
		TOTAL	3		15,520.00	1,250.00
	*Considerado apenas 1 desmobilização por ano					
	TOTAL C: DESMOBILIZAÇÃO INICIAL + CUSTO MÉDIO SONDAGEM/metro					1,250.00
	AMOSTRAGEM	DESCRIÇÃO	QUANTIDADE	CONSUMO MÊS	VALOR UNITÁRIO	CUSTO MENSAL SEM ENCARGOS
		Preparação da amostra*	1	-	20.00	-
		Transporte da amostra**	1	2.00	5,000.00	10,000.00
		Ensaios químicos (32 elementos)	1	-	50.00	-
		TOTAL	3		5,070.00	10,000.00
	*Varia de acordo com o número de amostras coletadas por mês/**Distância média de 1,000 km de distância para transporte e custo de R\$ 5.00/Km					
	TOTAL D: PREPARAÇÃO DE AMOSTRAS E ANÁLISES QUÍMICAS					11,250.00
TOTAL CUSTO FIXO POR MÊS (POR MÊS)					R\$	61,320.40
DESENVOLVIMENTO DE SONDAGEM POR MÊS (CONSIDERANDO 2 EQUIPAMENTOS)					m	1,200.00
TOTAL CUSTO VARIÁVEL (POR MÊS)*					R\$/m	12,500.00

*Não considera gastos com amostras e metragem perfurada

Figura 4.26 – Custos estimados para desenvolvimento de campanha de sondagem

Tabela 4.10 – Gastos estimados desembolsados nas distintas campanhas

Descrição	Pré-1998	1999	2000	2002	2003	Total
Total metros	14,484.96	22,946.88	45,261.21	4,848.88	7,832.42	95,374.35
Total amostras	11,816	12,480	24,411	3,422	5,719	57,848
Custos fixos anual	885,845	1,359,845	2,944,800	344,563	559,915	6,094,968
Custos sondagem + amostra	8,359,299.20	12,805,977.60	25,244,599.20	2,760,957.60	4,473,188.40	53,644,022.00
Custo total por ano (R\$)	9,245,144.00	14,165,822.40	28,189,399.20	3,105,520.80	5,033,103.60	643,728,264.00

Figura 4.27 – Estimativa de custos e total de metros perfurados

4.8 Correlação incertezas vs. investimento financeiro

Os gráficos apresentados na Figura 4.28 foram construídos segundo os valores referentes ao intervalo interquartis, obtido a partir dos diversos modelos simulados, e dos custos acumulados estimados para as distintas campanhas de sondagem. Os resultados de incerteza observados, demonstraram que existe a redução da incerteza associada ao aumento dos gastos ao longo dos anos. Nesta redução, ficou evidente que o aporte de investimentos desembolsado durante a campanha de 2000 foi o que impactou em na maior redução do índice de incerteza considerado, passando de 2,50 para 2,25 (-10%). Nos anos subsequentes, observa-se que, apesar de termos cercar de 9 milhos de Reais investidos, a redução não foi significativa, ocorrendo em média uma variação de no máximo 2% entre um ano e outro.

Em termos de metragem perfurada, a campanha efetuada no ano 2000, que refletiu a maior redução dos índices, representa quase 45% do total efetuado, já os anos onde não observou-se reduções significativas, totalizam menos de 15%.

Figura 4.28 – Relação investimentos vs. incertezas das distintas campanhas

CAPÍTULO 5 – CONCLUSÕES

A análise geoestatística proposta neste estudo teve como principal objetivo demonstrar a correlação existente entre o incremento dos dados e a redução das incertezas ao longo de distintas fases de pesquisa em um depósito real de cobre.

A metodologia proposta no Capítulo 3 teve sua aplicabilidade confirmada através dos resultados apresentados no Capítulo 4 e, de forma geral, os procedimentos empregados são amplamente conhecidos e de fácil implementação.

Na geração dos índices de incertezas foram realizadas 100 simulações para cada domínio e para cada campanha de sondagem, o que resultou em um total de 1.400 possíveis cenários analisados. Apesar de ser um número grande para processamento, o tempo médio gasto em cada um destes domínios mostrou-se totalmente viável para a execução em uma rotina de avaliação de recursos, não exigindo tempo de processamento e análise muito superiores aos já desenvolvidos para a estimativa dos valores ótimos.

Embora os resultados apresentados não tenham considerado a evolução da interpretação dos modelos geológicos, concluiu-se que o simples incremento de furos de sondagem em um depósito mineral tende a aproximar os teores estimados de um provável teor real do depósito, considerado neste trabalho como o resultado da krigagem ordinária.

Comparando-se os teores médios obtidos na krigagem ordinária para os dados da campanha 2003 com os teores médios obtidos nas distintas simulações realizadas, constata-se a influência do volume de informações no grau de incerteza do depósito. Os teores médios das simulações nas primeiras fases do projeto são superiores aos obtidos no final da pesquisa, que estão mais próximos dos valores krigados.

Com relação à análise dos investimentos apresentada, mesmo sendo bastante resumida se comparada aos custos reais desembolsados por uma empresa do setor mineral, em média, nota-se que, para um investimento de cerca de 15 milhões de Reais por campanha de sondagem, obtém-se uma redução significativa das incertezas, na ordem de 10 a 15%. Portanto, para reduções significativas, deve-se investir mais que o dobro do orçamento inicialmente proposto.

Nas campanhas mais recentes e posteriores à fase de maior investimento, observa-se uma variação de menos de 2% nos índices de incerteza, o que leva a concluir que mesmo investimentos próximos ao valor médio, na ordem de 9 milhões de Reais, não

são suficientes para a redução significativa das incertezas e, consequentemente, não contribuem para o incremento da confiabilidade dos recursos minerais, podendo este valor ser revertido para novas áreas de prospecção.

Ressalta-se que, para a real correlação entre os investimentos e a redução de incertezas nas distintas fases de pesquisa, seria prudente considerar, além do montante financeiro necessário para esta redução das incertezas, as variações na interpretação geológica que deverão ocorrer ao longo da pesquisa e a locação dos furos de sondagem que serão desenvolvidos. Esta locação deverá ser feita de forma adequada, visando a locais onde a variabilidade natural do depósito seja maior, o que proporciona maior redução da flutuação dos teores em cada etapa da pesquisa.

REFERENCIAS BIBLIOGRÁFICAS

- ANDRIOTTI, J. L. S. A. 1989. Introdução à geoestatística. Acta Geologica Leopoldensia. Nº 27. Vol. XI. Porto Alegre, RS. Companhia de Pesquisa de Recursos Minerais. p 7-82.
- ARROYO ORTIZ, C. E. 2008. Uma utilização de simulação geoestatística no tratamento das incertezas no planejamento de mina (manuscrito). Dissertação (Mestrado). Universidade Federal de Ouro Preto, Escola de Minas. Departamento de Engenharia de Minas. Ouro Preto, 132 p.
- AUSTRALASIAN INSTITUTE OF MINING AND METALLURGY. *Australasian code for reporting of exploration results, mineral resources and ore reserves – JORC Code*. dez, 2004. Disponível em: <http://www.jorc.org/jorc_code.asp>. Acesso em: 29 jul. 2015.
- CHIEREGATI, A. C. 2007. Reconciliação pró-ativa em empreendimentos mineiros. Tese (Doutorado). Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e de Petróleo. São Paulo, 201 p.
- CHILÈS, J. P. & DELFINER, P. 1999. *Geostatistics: Modeling Spatial Uncertainty*. Wiley-Interscience Publication, Wiley Series in Probability and Statistics, New York, 695 p.
- CHILÈS, J. P. & DELFINER, P. 2012. *Geostatistics: Modeling Spatial Uncertainty*. Wiley-Interscience Publication, Wiley Series in Probability and Statistics, New York, 2º Edition, 699 p.
- CORREA, S. M. B. B. 2003. Probabilidade e estatística. 2º Ed. Belo Horizonte: PUC Minas Virtual. 116 p.
- DEUTSCH, C. V. & JOURNAL, A. G., 1992. *GSLIB: Geostatistical Software Library and User's Guide*. Oxford University Press, New York, 340 p.

- DEUTSCH, C. V. & JOURNAL, A. G., 1998. *GSLIB: Geostatistical Software Library and User's Guide*. Oxford University Press, New York, 2° Edition, 369 p.
- DIEDRICH, C. 2012. Incorporação da variabilidade dos teores para análise de risco de recursos minerais e sequenciamento de lavra. Dissertação (Mestrado em Engenharia – Tecnologia Mineral) – Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e dos Materiais-PPGEM, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- DIMITRAKOPOULOS, R., 1998. *Conditional simulation algorithms for modeling orebody uncertainty in open pit optimization*. International Journal of Surface Mining, Reclamation and Environment, nº 12, pp. 173-179.
- GOOVAERTS, P. 1997. *Geostatistics for Natural Resources Evaluation*. Oxford University Press, New yourk, 483 p.
- GOOVAERTS, P. 1999. *Geostatistics in soilscience: state-of-the-art and perspectives*. Geoderma 89, 1-45.
- HUIJBREGTS, C. L. 1975. *Regionalized Variables and Quantitative Analysis of Spatial Data*. In: Davis, J. C. & McCullagh, M. J. (orgs.). *Display and Analysis of Spatial Data*. New York, John Wiley, pp. 38-53.
- ISAAKS, E.H., SRIVASTAVA, M. 1989. *Applied Geostatistics*. Oxford University Press, New York, 561 p.
- JOURNAL, A. G. 1974. *Geostatistics for Conditional Simulation of Ore Bodies*. Economic Geology, Vol. 69, nº 5, p. 673-687.
- JOURNAL, A. G. & HUIKBREGTS, C. J. 1978. *Mining Geostatistics*. Academic Press, London, 600p.

- JOURNEL, A. G. 1989. *Fundamentals of Geostatistics in Five Lessons*. 28th International Geological Congress. American Geophysical Union, Washington, D.C., Short Course in Geology, Vol. 5, 40 p.
- JOURNEL, A. G.; KYRIAKIDIS, P. C. e MAO, S. 2000. *Correcting the smoothing effect of estimators: A spectral post processor*. Mathematical Geology, vol. 32, n° 7. p. 787-813.
- KOCH JR., G. S., LINK, R. F. 1970. *Statistical Analysis of Geological Data*. New York: Dover Publications. v. 1, 375 p.
- LANDIM, P. M. B. 2003. *Análise estatística de dados geológicos*. Fundação Editora UNESP, 2ª edição.
- MAIA, P. C. 2001. *Investimento sob incerteza em mineração de ferro: o valor da flexibilidade em decisões de capacidade e escoamento*. Dissertação (Mestrado). Departamento de Engenharia de Produção. Universidade Federal de Minas Gerais. Belo Horizonte, MG, 125 p.
- MANN, C. J. 1993. *Uncertainty in Geology*. In: DAVIS, J. C. & HERZFELD, U. C. 1993 *Computers in Geology – 25 Years of Progress*. Oxford University Press, New York. 241-254 p.
- MATHERON, G. 1965. *Les variables régionalisées et leur estimation*. Paris: Masson, 1965.
- MATHERON, G. 1973. *The Intrinsic Random Functions and Their Applications*. Advances in Applied Probability, n° 5, p. 4 39-468.
- MORLEY, C. SNOWDEN, V., DAY, D. 2003. *Financial impact of resource/reserve uncertainty*. Colloquium on Bankable Feasibility Studies and Project Financing for Mining Projects (South African Institute of Mining and Metallurgy: Johannesburg). 70-82 p.

- MONTEIRO, L.V.S., XAVIER, R.P., CARVALHO, E.R., HITZMAN, M.W., JOHNSON, C.A., SOUZA FILHO, C.R., TORRESI, I., 2008a. *Spatial and temporal zoning of hydrothermal alteration and mineralization in the Sossego iron oxide–copper–gold deposit, Carajás Mineral Province, Brazil: paragenesis and stable isotope constraints*. *Miner. Depos.* 43, 129–159.
- MONTEIRO, L.V.S., XAVIER, R.P., HITZMAN, M.W., JULIANI, C., SOUZA FILHO, C.R., CARVALHO, E.R., 2008b. *Mineral chemistry of ore and hydrothermal alteration at the Sossego iron oxide–copper–gold deposit, Carajás Mineral Province, Brazil*. *Ore Geol Rev.* 34, 317–336.
- MORETO, C. P. N. 2010. O depósito de óxido de ferro-cobre-ouro Bacaba, província Mineral de Carajás, PA: Geocronologia U-Pb das rochas hospedeiras. Dissertação (Mestrado). Universidade Estadual de Campinas, Instituto de Geociências. Campinas, SP.
- MYERS, J. C. 1996. *Geostatistical Error Management: Quantifying Uncertainty For Enviromental Sampling And Mapping*. Van Nostrand Reinhold, New York, USA, 545 p.
- NEUFELD, C. T. 2005. *Guide to Recoverable Reserves with Uniform Conditioning*. Centre for Computational Geostatistics (CCG). Guidebook Series Vol. 4. Edmonton, AB, Canada. 31 p.
- NOPPÉ, M. 2004. *Reconciliation: importance of good sampling and data QA-QC*. In: Mining and Resource Geology Symposium, Queensland, Australia.
- OLEA, R. A. (ed.), 1991. *Geostatistical Glossary and Multilingual Dictionary. International Association for Mathematical Geology Studies in Mathematical Geology*. Nº 3. Oxford University Press.
- OLEA, R. A., 1994 . *Fundamentals of Semivariogram Estimation, Modeling and Usage. Chapter 4*. In: Yarus, J. M & Chambers, R. L (eds.). *Stochastic*

Modeling and Geostatistics: Principles, Methods, and Case Studies. AAPG Computer Applications in Geology, Nº 3.

OLEA, R. A. 1999. *Geostatistics for Engineers and Earth Scientists*. Kluwer Academic Publishers. 303 p.

PILGER, G. G., 2000. Critérios para locação amostral baseados em simulação estocástica. Dissertação (Mestrado). Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e de Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 127 p.

PITARD, F. F., 1993. *Pierre Gy's sampling theory and practice: Heterogeneity, Sampling, Correctness and Statistical Process Control*, 2º ed. CRC Press: Boca Raton, FL.

PYRCZ, M. J. & DEUTSCH, C. V. 2014. *Geostatistical Reservoir Modeling*. Oxford University Press, New York, 2º Edition, 429 p.

RIVOIRARD, J. 2005. *Concepts and methods of geostatistics*. In: Bilodeau M., Meyer F. and Schmitt M. (eds.), *Space, Structure and Randomness - Contributions in Honor of Georges Matheron in the Field of Geostatistics, Random Sets and Mathematical Morphology*: Springer, New York, p. 17-37.

ROSSI, M. E. & DEUTSCH, C. V. 2013. *Mineral Resource Estimation*. New York Inc: Springer, 2014. 332 p.

ROZMAN, L. I. 1998. *Measuring and managing the risk in resource and reserves*. Ore Reserves and Finance Seminar. AusIMM, Sydney.

SILVA, N. C. S. Metodologia de planejamento estratégico de lavra incorporando riscos e incertezas para obtenção de resultados operacionais. Tese (Doutorado). Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e Petróleo. São Paulo. 124 p.

- SINCLAIR, A. J., BLACKWELL, G. H., 2004. *Applied mineral inventory estimation*. Cambridge: Cambridge University Press. 381 p
- SOUZA, E. S. 2007. Proposição Geoestatística para quantificação do erro em estimativas de tonelagens e teores. Tese (Doutorado). Programa de Pós-Graduação em Engenharia de Minas, Metalurgia e de Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 193 p.
- STEVENS, S. S. 1946. *On the theory of scales of measurement*. Science, v. 103, n. 2.684, p. 677-680.
- TRAJANO, R. B., 1963 – Amostragem. *Eng, Min. & Met.*, XXXVIII (220): 149-154.
- TRIGEORGIS, L. 1996 – *Real Options: managerial flexibility and strategy in resource allocation*. The MIT Press, Cambridge.
- YAMAMOTO, J. K. 1998. *A Review of Numerical Methods for the Interpolation of Geological Data*. Mathematical Geology, vol. 32, nº 4. p. 489-509.
- YAMAMOTO, J. K. 2000. *An Alternative Measure of the Reliability of Ordinary Kriging Estimates*. Mathematical Geology, vol. 32. Nº 4. p. 489-509.
- YAMAMOTO, J. K. & ROCHA, M. M. 2001. Conceitos Básicos. In: YAMAMOTO, J. K. 2001 (ed.). Avaliação e Classificação de Reservas Minerais. Editora da Universidade de São Paulo, São Paulo, 225 p.
- YAMAMOTO, J. K. BETTENCOURT, J. S. MONTANHEIRO, T. S. 2001. Análise Estatística. In: YAMAMOTO, J. K. 2001 (ed.). Avaliação e Classificação de Reservas Minerais. Editora da Universidade de São Paulo, São Paulo, 225 p.
- YAMAMOTO, J. K. 2001. Análise Geoestatística. In: YAMAMOTO, J. K. 2001 (ed.). Avaliação e Classificação de Reservas Minerais. Editora da Universidade de São Paulo, São Paulo, 225 p.

YAMAMOTO, J. K. 2001. Avaliação e Classificação de Reservas Minerais. Editora da Universidade de São Paulo, São Paulo, 225 p.

YAMAMOTO, J. K. & LANDIM, P. M. B. 2013. Geoestatística: Conceitos e Aplicações. Editora Oficina de Textos, São Paulo, 215 p.

ANEXO A – Histograma Dados Brutos

Histograma de CU_% - Dados 2002

Variável de painel: MINERIO

Histograma de CU_% - Dados 2003

Variável de painel: MINERIO

ANEXO B – Gráficos de Probabilidade

Gráfico de Probabilidade de CU_% - Dados 2000
Lognormal - IC de 95%

Variável de painel: MINERIO

Gráfico de Probabilidade de CU_% - Dados 2002
Lognormal - IC de 95%

Variável de painel: MINERIO

ANEXO C – Boxplot dos Dados Compositados

ANEXO D – Histograma dos Dados Compositados

ANEXO E – Mapa de Análise Variográfica em Superfície

ANEXO F – Validação por Médias Móveis da Krigagem Ordinária

ANEXO G – GRÁFICOS DE AJUSTE DE FUNÇÃO ANAMORFOSE E HISTOGRAMAS DAS VARIÁVEIS TRANSFORMADAS

Brecha Sulfetada - Dados 1999

Grupo 1 - Dados 1999

Sulfeto Disseminado - Dados 2000

Brecha Sulfetada - Dados 2000

Grupo 1 - Dados 2000

Sulfeto Disseminado - Dados 2002

Brecha Sulfetada - Dados 2002

Grupo 1 - Dados 2002

ANEXO H – Gráficos de Validação da Simulação

Variograma/Madograma (CU_GAUSS) - Misto Flotacao + Brecha Sulfetada
Dados 1998

Variograma/Madograma (CU_GAUSS) - Sulfeto Disseminado
Dados 1998

Variograma/Madograma (CU_GAUSS) - Brecha Sulfetada
Dados 1999

Variograma/Madograma (CU_GAUSS) - Sulfeto Disseminado
Dados 1999

Variograma/Madograma (CU_GAUSS) - Misto Lixiviacao + Misto Flotacao
Dados 1999

Variograma/Madograma (CU_GAUSS) - Brecha Sulfetada Variograma/Madograma (CU_3_NS) - Sulfeto Dissemiando
Dados 2000

Variograma/Madograma (CU_GAUSS)
Misto Lixiviacao + Misto Flotacao - Dados 2000

Variogram/Madograma (CU_GAUSS) - Brecha Sulfetada Variograma/Madograma (CU_GAUSS) - Sulfeto Disseminado
Dados 2002

Variograma/Madograma (CU_GAUSS) - Misto Lixiviacao + Misto Flotacao
Dados 2002

ANEXO I – Variogramas Experimentais e Modelos Ajustados

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	Omnidirecional	0.25	0.45	Esférico	10	0.38	Esférico	120
Grupo 2	Omnidirecional	0.14	0.66	Esférico	5.5	0.18	Esférico	21.5

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura			Terceira Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	N300°	0.5	0.43	Esférico	110	0.1	Esférico	50000	0.125	Esférico	100000
	N210°/80°NW				65			100			750
	Plano ortogonal				60			150			200
Brecha Sulfetada	Omnidirecional	0.25	0.5	Esférico	10	0.25	Esférico	17	-	-	-
Grupo 1	Omnidirecional	-	0.2	Esférico	3.5	8.5	Esférico	220	-	-	-

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura			Terceira Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	N130°	0.3	0.35	Esférico	70	0.35	Esférico	180	0.12	Esférico	224
	N220°/10°SW				45			120			100000
	Plano ortogonal				10			230			100000
Brecha Sulfetada	N90°	0.23	0.52	Esférico	77	0.18	Esférico	80	0.07	Esférico	96
	N180°/60°NW				7			28			10000
	Plano ortogonal				75			80			500
Grupo 1	Omnidirecional	0.0777	0.25	Esférico	3.5	0.6	Esférico	23	-	-	-

Domínio	Direção	Efeito Pepita	Primeira Estrutura			Segunda Estrutura		
			Patamar	Tipo	Alcance	Patamar	Tipo	Alcance
Sulfeto Disseminado	N40°	0.19	0.7	Esférico	110	0.45	Esférico	500
	N130°				50			1300
	Plano ortogonal				18			8000
Brecha Sulfetada	N120°	0.3	0.6	Esférico	80	0.1	Esférico	118
	N210°/40°NW				95			220
	Plano ortogonal				7			35
Grupo 1	Omnidirecional	0.4	0.2	Esférico	55	0.4	Esférico	145

ANEXO J – Parâmetros de Vizinhança Utilizados na Simulação

Parâmetros - 1998	Sulfeto Disseminado	Grupo 2	
Eixo Maior	120	220	
Eixo Intermediário	120	220	
Eixo Menor	120	44	
Nº aleatório (<i>seed</i>)	4,120	32,100	
Mínimo de amostras	3	3	
Nº de setores angulares	8	4	
Máximo de amostras por setor	2	2	
Nº máximo de blocos previamente simulados	4	4	
Distância mínimo entre duas amostras selecionadas	2	2	
Parâmetros - 1999	Sulfeto Disseminado	Grupo 1	Brecha Sulfetada
Eixo Maior	110	150	17
Eixo Intermediário	65	150	17
Eixo Menor	60	150	17
Nº aleatório (<i>seed</i>)	356	555	1,235
Mínimo de amostras	3	2	3
Nº de setores angulares	4	8	4
Máximo de amostras por setor	2	2	2
Nº máximo de blocos previamente simulados	4	4	5
Distância mínimo entre duas amostras selecionadas	2	2	1
Parâmetros - 2000	Sulfeto Disseminado	Grupo 1	Brecha Sulfetada
Eixo Maior	90	8,5	96
Eixo Intermediário	85	8,5	80
Eixo Menor	20	8,5	46
Nº aleatório (<i>seed</i>)	23,145	12,546	12,451
Mínimo de amostras	3	3	3
Nº de setores angulares	4	4	4
Máximo de amostras por setor	2	2	2
Nº máximo de blocos previamente simulados	4	4	4
Distância mínimo entre duas amostras selecionadas	2	2	2
Parâmetros - 2002	Sulfeto Disseminado	Grupo 1	Brecha Sulfetada
Eixo Maior	134	180	120
Eixo Intermediário	50	180	120
Eixo Menor	20	180	15
Nº aleatório (<i>seed</i>)	147,876	245,879	215,489
Mínimo de amostras	3	3	3
Nº de setores angulares	8	4	4
Máximo de amostras por setor	2	3	2
Nº máximo de blocos previamente simulados	5	4	4
Distância mínimo entre duas amostras selecionadas	2	1	2

ANEXO K – Valores Médios das Simulações vs. Valor Médio Obtido na Krigagem Ordinária

ANEXO L – Histogramas de Validação