MATHEUS MAGALHÃES PEREIRA DE ANDRADE

**CLASSIFICAÇÃO DE RECURSOS MINERAIS POR MEIO DE SIMULAÇÃO
CONDICIONAL E INTERVALO DE CONFIANÇA DA MÉDIA APLICADA AO
SULFETO DISSEMINADO DO CORPO DE MINÉRIO SEQUEIRINHO, DEPÓSITO
SOSSEGO, PROVÍNCIA MINERAL CARAJÁS**

Dissertação apresentada ao Instituto de
Geociências da Universidade de São Paulo para a
obtenção do título de Mestre em Ciências.

Área de Concentração: Recursos Minerais e Meio
Ambiente

Orientador: Prof. Dr. Marcelo Monteiro da Rocha.

São Paulo
2018

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

Serviço de Biblioteca e Documentação do IGc/USP

Ficha catalográfica gerada automaticamente com dados fornecidos pelo(a) autor(a)
via programa desenvolvido pela Seção Técnica de Informática do ICMC/USP

Bibliotecários responsáveis pela estrutura de catalogação da publicação:
Sonia Regina Yole Guerra - CRB-8/4208 | Anderson de Santana - CRB-8/6658

Magalhães Pereira de Andrade, Matheus

Classificação de recursos minerais por meio de
simulação condicional e intervalo de confiança da
média aplicada ao sulfeto disseminado do corpo de
minério Sequeirinho, depósito Sossego, Província
Mineral Carajás / Matheus Magalhães Pereira de
Andrade; orientador Marcelo Monteiro da Rocha. --
São Paulo, 2018.

106 p.

Dissertação (Mestrado - Programa de Pós-Graduação
em Recursos Minerais e Hidrogeologia) -- Instituto
de Geociências, Universidade de São Paulo, 2018.

1. GEOESTATÍSTICA. 2. SIMULAÇÃO SEQUENCIAL
GAUSSIANA. 3. INCERTEZA. I. Monteiro da Rocha,
Marcelo, orient. II. Título.

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE GEOCIÊNCIAS

**Classificação de recursos minerais por meio de simulação
condicional e intervalo de confiança da média aplicada ao sulfeto
disseminado do corpo de minério Sequeirinho, depósito Sossego,
Província Mineral Carajás**

MATHEUS MAGALHÃES PEREIRA DE ANDRADE

Orientador: Prof. Dr. Marcelo Monteiro da Rocha

Dissertação de Mestrado

Nº 811

COMISSÃO JULGADORA

Dr. Marcelo Monteiro da Rocha

Dra. Lília Mascarenhas Sant'Agostino

Dr. Giorgio Francesco Cesare de Tomi

Dr. Paulo Milton Barbosa Landim

SÃO PAULO
2018

À minha família

AGRADECIMENTOS

Agradeço a todos que contribuíram de alguma forma para que eu concluísse este trabalho. Acredito que cada contribuição, ajuda e apoio foram essenciais para que meus objetivos acadêmicos fossem alcançados.

Inicialmente agradeço a todas as instituições que deram suporte ao desenvolvimento desta dissertação:

- aos professores e funcionários do Instituto de Geociências;
- à empresa Vale S.A. pela disponibilização dos dados e ao engenheiro Sandro Freitas pelas informações compartilhadas;
- à CAPES pela bolsa de estudos;
- à Geovariances Brasil pela cessão do software Isatis;
- à Datamine América do Sul pela cessão do software Studio RM;

Ao Prof. Dr. Marcelo Monteiro da Rocha agradeço pela orientação e ensinamentos ao longo desses dois anos de imersão no mundo da geoestatística e por todas as valiosas discussões que contribuíram enormemente para a conclusão deste trabalho.

Agradeço especialmente ao grande amigo e mestre em geoestatística Eduardo Takafuji por me incentivar a ingressar no mestrado com geoestatística e me ensinar com muito entusiasmo muitos dos temas discutidos neste trabalho. Da mesma forma agradeço ao Gustavo Ramos e ao Santiago Diaz por dividirem comigo seus conhecimentos em estatística e geoestatística, e ao Antonio Tadashi Kikuda pela solicitude no Laboratório de Informática Geológica.

Agradeço às geoestatísticas Talita Ferreira, pelas dicas e esclarecimentos sobre os dados, e Maira Santos, pelas discussões sobre classificação de recursos minerais e softwares.

Agradeço ao amigo Gustavo Usero por muito ter me incentivado a seguir buscando conhecimento na área de geoestatística aplicada a classificação de recursos minerais.

Agradeço à equipe da Geokrigagem pelo apoio e cursos que foram essenciais para o enriquecimento desta dissertação.

Aos amigos do Instituto de Geociências, aos membros do Student Chapter Society of Economic Geologists (especialmente ao comitê executivo) e a todos os

geólogos e geofísicos que estiveram juntos comigo nesta etapa de aprendizado, registro aqui meu "Muito Obrigado!".

Agradeço aos meus pais (João e Delma) por sempre apoiarem minhas decisões e porque sempre me incentivam na busca por conhecimento.

Um agradecimento especial à Rafaella, por todo apoio, incentivo e carinho durante o desenvolvimento deste mestrado.

*“...we balance probabilities and choose the most likely.
It is the scientific use of the imagination.”*

Arthur Conan Doyle

RESUMO

ANDRADE, M. M. P. **Classificação de recursos minerais por meio de simulação condicional e intervalo de confiança da média aplicada ao Sulfeto Disseminado do Corpo de Minério Sequeirinho, Depósito Sossego, Província Mineral Carajás.** 2018. 106 p. Dissertação (Mestrado em Recursos Minerais e Meio Ambiente) – Instituto de Geociências, Universidade de São Paulo, São Paulo.

A classificação de recursos e reservas minerais deve atender aos requisitos de padrões internacionais criados para garantir transparência aos empreendimentos mineiros e, desta forma, dar segurança aos investidores. Esses padrões recomendam que os recursos minerais sejam classificados em medido, indicado e inferido. Entre os métodos de classificação internacionalmente aceitos, acredita-se que quantificação de incertezas por meio de simulação condicional e intervalos de confiança é uma alternativa mais completa em relação a métodos tradicionalmente utilizados porque considera a variabilidade local dos dados amostrais e apresenta como vantagem a incorporação de incerteza para a definição das classes de recursos minerais. Neste trabalho foi feita a classificação de recursos minerais para cobre (sulfeto disseminado) do Corpo de Minério Sequeirinho, parte do Depósito de Óxido de ferro-cobre-ouro Sossego, um depósito mineral de classe mundial localizado em Canaã dos Carajás-PA, Brasil. Para esta classificação foram utilizadas 20.268 amostras do litotipo sulfeto disseminado proveniente de campanhas de sondagem realizadas entre 1997 e 2003 na cava Sequeirinho. Os intervalos de incerteza definidos foram adaptados dos comumente utilizados na indústria mineral (Rossi e Deutsch, 2014): 0-15% para recurso mineral medido, 15-30% para recursos mineral indicado e 30-100% para recurso mineral inferido, todos calculados com um nível de confiança de 90% para blocos com teor de corte de 0,33% de cobre. O recurso mineral medido totalizou 74,2 milhões de toneladas a um teor médio de cobre de 1,62%, o recurso mineral indicado apresentou 51,2 milhões de toneladas a um teor médio de 0,67% de cobre e recurso mineral inferido apresentou 24,6 milhões de toneladas a um teor médio de 0,41% de cobre, considerando um teor de corte de 0,33%. Tendo em vista que os padrões internacionais incentivam a utilização de incerteza para a classificação, mas não

definem quais parâmetros devem ser utilizados, novas classificações foram feitas a partir de variações nos intervalos de incerteza para cada classe de recurso mineral com o objetivo de comparar os resultados. Notou-se com os resultados das novas classificações que este método apresenta sensibilidade a pequenas variações dos intervalos de incerteza utilizados para a definição das classes de recursos minerais e que o tipo de distribuição de frequência dos dados amostrais tem papel importante na escolha desses intervalos. Desta forma depósitos que apresentam alta variabilidade devem ser tratados de forma diferente dos depósitos de baixa variabilidade quando se trata da escolha de intervalos de incerteza para a classificação de recursos minerais.

Palavras-chave: Geoestatística. Simulação Sequencial Gaussiana. Incerteza.

ABSTRACT

ANDRADE, M. M. P. **Mineral Resource Classification through conditional simulation and confidence interval of the mean applied to the disseminated sulphide of the Sequeirinho orebody, Sossego deposit, Carajás Mineral Province, Brazil.** 2018. 106 p. Dissertação (Mestrado em Recursos Minerais e Meio Ambiente) – Instituto de Geociências, Universidade de São Paulo, São Paulo.

The classification of mineral resources and reserves should comply with the requirements of the international reporting standards that was created to ensure transparency of the mining companies and to provide protection to the investors. Those standards require that mineral resource must be classified as measured, indicated or inferred. Among internationally accepted classification methods, it is believed that quantification of uncertainties through conditional simulation and confidence intervals is a more complete alternative to traditional methods because it considers the local variability of the sample data and presents as an advantage the incorporation of uncertainty for the mineral resource class definition. In this dissertation, the mineral resource classification was made for the Copper of the Sequeirinho orebody, part of Sossego iron oxide–copper–gold deposit, a world-class mineral deposit located at Carajás Mineral Province, Brazil. For this classification, 20,268 samples of the disseminated sulphide lithotype were used, from surveys conducted between 1997 and 2003 in the Sequeirinho open pit. The uncertainty intervals defined was adapted from the typically used by the mineral industry (Rossi and Deutsch, 2014): 0-15% for the measured mineral resource, 15-30% for the indicated mineral resource, and 30-100% for the inferred mineral resource, all calculated with a confidence level of 90%. The measured mineral resource added 74,2 million tons at an average of 1.62% copper content, the indicated mineral resource added 51.2 million tons at an average of 0.67% copper content and the inferred mineral resource added 24.6 million tons at an average of 0.41% copper content, considering a cut-off of 0.33%. Given that international standards encourage the use of uncertainty for classification without the definition about which parameters must be used, new classifications were made from variations in the uncertainty intervals for each class of mineral resource in order to compare the results. From the results of the new classifications, it is noticed that this method is sensitive to small variations in the uncertainty intervals used to define the mineral

resource classes and the type of frequency distribution of sample data plays an important role in choosing these ranges. Therefore, high variability deposits must be treated differently from low variability deposits when it comes to the definition of uncertainty intervals for mineral resource classification.

Keywords: Geostatistics. Sequential Gaussian Simulation. Uncertainty.

SUMÁRIO

1.	Introdução.....	21
2.	Objetivos.....	22
3.	Revisão da Literatura.....	23
3.1	Estatística.....	23
3.1.1	Distribuição de Frequências	23
3.1.2	Estatística Descritiva	25
3.1.3	Teorema do Limite Central	28
3.1.4	Intervalo de Confiança da Média	28
3.2	Geoestatística	30
3.2.1	Variáveis Regionalizadas	30
3.2.2	Variograma	31
3.2.3	Validação Cruzada	32
3.2.4	Anisotropias	33
3.2.5	Krigagem Ordinária.....	33
3.2.6	Krigagem Indicadora.....	35
3.2.7	Krigagem Simples.....	36
3.2.8	Simulação Condicional Geoestatística	37
3.2.9	Simulação Sequencial Gaussiana	38
3.3	Transformação de dados.....	39
3.3.1	Transformação Gaussiana	39
3.3.2	Verificação de Multigaussianidade	40
3.4	Erro e Incertezas	41
3.4.1	Erro.....	41
3.4.2	Incerteza e fontes de incerteza em investigações geológicas	41
3.4.3	Modelos de Incerteza	43
3.5	Classificação de Recursos Minerais.....	43

3.5.1	Metodologias de Classificação de Recursos Minerais por meio da quantificação da incerteza	44
3.5.2	Histórico e Desenvolvimento dos Códigos Internacionais de Declaração de Recursos e Reservas Minerais	47
3.5.3	Classificação de Recursos minerais: CRIRSCO (2013)	50
3.6	Contexto Geológico da Área de Estudo	52
3.6.1	Depósito de óxido de Ferro-Cobre-Ouro Sossego	53
4.	Materiais e Métodos	55
4.1	Base de dados	56
4.1.1	Modelo de blocos	56
4.2	Validação da Base de dados	57
4.2.1	Modelo do Corpo de Minério	57
4.3	Métodos	57
5.	Resultados e Discussão	59
5.1	Análise exploratória dos dados	59
5.2	Regularização das amostras	62
5.3	Estimativa do corpo de minério por krigagem de variáveis indicadoras 64	
5.3.1	Variogramas das variáveis indicadoras	65
5.3.2	Krigagem ordinária de variáveis indicadoras	66
5.4	Estimativa de teores por krigagem ordinária	69
5.4.1	Variogramas	69
5.4.2	Validação Cruzada	72
5.4.3	Krigagem Ordinária	72
5.5	Simulação Condicional	75
5.5.1	Transformação dos dados	75
5.5.2	Variogramas	76
5.5.3	Validação Cruzada	78

5.5.4 Simulação Sequencial Gaussiana	79
5.6 Cálculo de incerteza	83
5.7 Classificação de blocos	84
5.8 Variação dos Intervalos de Incerteza	88
5.9 Comparação com o método tradicional	94
6. Considerações Finais	99
7. Referências Bibliográficas	101
ANEXO A – Tabelas	107
ANEXO B – Figuras	113

LISTA DE ILUSTRAÇÕES

<i>Figura 1: Exemplo de distribuição de frequência, onde a altura de cada coluna representa o número de observações para o correspondente intervalo x.</i>	23
<i>Figura 2: Valores específicos de z em unidades de desvio padrão (σ) que abrangem certas percentagens de observações simetricamente em torno da média.</i>	24
<i>Figura 3: Esboço de distribuição lognormal.</i>	26
<i>Figura 4: Representação de diferentes tamanhos de variâncias.</i>	27
<i>Figura 5: Variograma com patamar típico e suas propriedades.</i>	32
<i>Figura 6: Tipos de Anisotropias.</i>	33
<i>Figura 7: Transformação Gaussiana por meio da função de distribuição acumulada.</i>	40
<i>Figura 8: Quadro ilustrativo da classificação de Recursos e Reservas Minerais.</i>	44
<i>Figura 9: Países membros do CRIRSCO em Julho de 2018.</i>	50
<i>Figura 10: (A) Mapa geológico simplificado da região do Complexo de Mineração Sossego (modificado de VALE por Monteiro et al., 2008a).</i>	54
<i>Figura 11: Seção esquemática do corpo de minério Sequeirinho.</i>	55
<i>Figura 12: Vista aérea da Cava Sequeirinho.</i>	55
<i>Figura 13: Fluxograma que compreende as principais etapas da metodologia proposta.</i>	60
<i>Figura 14: Histograma para a Variável Cu% no depósito mineral.</i>	61
<i>Figura 15: Histograma para a Variável Cu% em amostras de Sulfeto disseminado no depósito mineral.</i>	61
<i>Figura 16: Distribuição da variável Cu (%) para amostras antes (A) e após (B) a regularização.</i>	62
<i>Figura 17: Distribuição dos comprimentos (m) para amostras antes (A) e após (B) a regularização.</i>	63
<i>Figura 18: Diagrama dos dados de Cu (%) versus comprimento das amostras regularizadas.</i>	64
<i>Figura 19: Distribuição das variáveis após a transformação para indicadoras.</i>	65
<i>Figura 20: Variogramas experimentais e modelo teórico de variograma para a variável indicadora DISS.</i>	66
<i>Figura 21: Modelo resultante da krigagem indicadora.</i>	68
<i>Figura 22: Modelo resultante da krigagem indicadora com blocos com mais 50% de probabilidade de ocorrência de Sulfeto Disseminado.</i>	68
<i>Figura 23: Contorno do corpo mineralizado preenchido por blocos do modelo probabilístico de ocorrência de Sulfeto Disseminado visto em planta (cota 48 m).</i>	69
<i>Figura 24: (A) Mapa geológico simplificado do depósito do sossego e seus corpos mineralizados (Monteiro et al., 2008a); (B) Corpo de minério Sequeirinho (Monteiro et al., 2008a); (C) Modelo do corpo de minério Sequeirinho construído por krigagem indicadora.</i>	70
<i>Figura 25: Elipsóide rotacionado de acordo com a anisotropia para Cu (%).</i>	71
<i>Figura 26: Variogramas experimentais e modelo de variograma para a variável Cu(%).</i>	71
<i>Figura 27: Diagrama de dispersão entre os valores amostrais e estimados para a variável cobre.</i>	73
<i>Figura 28: Histograma dos dados obtidos por krigagem ordinária.</i>	74

<i>Figura 29: Modelo resultante de krigagem ordinária para Cu (%).</i>	74
<i>Figura 30: Distribuição dos dados de CU (%) transformados por nscore.</i>	75
<i>Figura 31: Teste de bigaussianidade: raiz quadrada do variograma / madograma.</i>	76
<i>Figura 32: Variogramas experimentais e modelo de variograma para a variável Cu(%) transformada por nscore.</i>	77
<i>Figura 33: Diagrama de dispersão entre os valores amostrais e estimados para a variável cobre transformados por normal score.</i>	78
<i>Figura 34: Realização n° 15 resultante da simulação para teores de CU(%) no campo Gaussiano.</i>	80
<i>Figura 35: Realização n° 15 resultante da simulação para teores de CU(%) após a transformação inversa.</i>	81
<i>Figura 36: Gráfico de validação das médias (Cu %) das realizações após a transformação inversa comparadas às médias dos dados e à média da krigagem ordinária.</i>	82
<i>Figura 37: Distribuição da variável Cu(%) nas realizações 5, 27, 76, 94 (escolhidas ao acaso).</i>	83
<i>Figura 38: Diagramas Quantil-Quantil (Q-Q) das realizações 5, 27, 76, 94 comparadas a distribuição de Cu (%) nos dados de entrada.</i>	84
<i>Figura 39: Blocos estimados por krigagem ordinária com teor maior do que o teor de corte de 0,33% de cobre.</i>	85
<i>Figura 40: Classes de recursos minerais em visualização 3D.</i>	87
<i>Figura 41: Volume das classes de recursos minerais em metros cúbicos.</i>	87
<i>Figura 42: Variações do intervalos e incerteza para classificação de recursos minerais.</i>	89
<i>Figura 43: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral medido (frequência expressa em número de blocos).</i>	91
<i>Figura 44: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral indicado (frequência expressa em número de blocos).</i>	92
<i>Figura 45: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral inferido (frequência expressa em número de blocos).</i>	92
<i>Figura 46: Coeficientes de Variação da Tabela 45.</i>	93
<i>Figura 47: Classificação de Recursos Minerais por restrição da vizinhança de krigagem.</i>	95
<i>Figura 48: Resultado da classificação de recursos minerais por meio do método de restrição da vizinhança de krigagem.</i>	96
<i>Figura 49: Estimativa de bloco utilizando amostras com mesma configuração espacial e diferentes variabilidades locais de teores.</i>	97
<i>Figura 50: Blocos classificados com medidos pelo método de restrição da vizinhança de krigagem que apresentam incerteza maior que 40%.</i>	98
<i>Figura 51: Mapa base da localização das sondagens de diferentes campanhas que deram origem a base de dados utilizada neste trabalho.</i>	113

LISTA DE TABELAS

<i>Tabela 1: Estatísticas descritivas dos dados de Cu (%) no depósito mineral.</i>	59
<i>Tabela 2: Estatísticas descritivas dos dados de Cu (%) para o Sulfeto Disseminado no depósito mineral.</i>	59
<i>Tabela 3: Estatísticas dos dados de Cu (%) para o Sulfeto Disseminado no corpo de Minério</i>	63
<i>Tabela 4: Estatísticas dos dados de Cu (%) para o Sulfeto Disseminado no corpo de minério após a regularização.</i>	63
<i>Tabela 5: Parâmetros de cálculo do variograma experimental.</i>	65
<i>Tabela 6: Parâmetros de ajuste do modelo de variograma.</i>	65
<i>Tabela 7: Parâmetros de busca para a krigagem indicadora.</i>	67
<i>Tabela 8: Parâmetros de cálculo do variograma experimental.</i>	70
<i>Tabela 9: Parâmetros de ajuste do modelo de variograma para Cu (%).</i>	72
<i>Tabela 10: Parâmetros de vizinhança para a busca por amostras definidas na validação cruzada.</i>	72
<i>Tabela 11: Parâmetros para discretização de bloco.</i>	73
<i>Tabela 12: Estatísticas descritivas do modelo obtido pela krigagem ordinária.</i>	74
<i>Tabela 13: Estatísticas descritivas dos dados de Cu (%) transformados por nscore.</i>	75
<i>Tabela 14: Parâmetros de cálculo do variograma experimental.</i>	76
<i>Tabela 15: Parâmetros de ajuste do modelo de variograma.</i>	77
<i>Tabela 16: Parâmetros de busca para a Simulação Sequencial Gaussiana.</i>	79
<i>Tabela 17: Parâmetros da Correção de Suporte.</i>	79
<i>Tabela 18: Estatísticas da realização número 15 no campo Gaussiano.</i>	80
<i>Tabela 19: Estatísticas da realização número 15 após a transformação inversa.</i>	81
<i>Tabela 20: Teores de corte estratégicos entre os anos de 2011 e 2022.</i>	85
<i>Tabela 21: Resultado da classificação de recursos minerais em volume e em toneladas de metal contido.</i>	86
<i>Tabela 22: Parâmetros de incerteza utilizados para a classificação.</i>	88
<i>Tabela 23: Volumes quantificados por classe com diferentes intervalos de incerteza.</i>	89
<i>Tabela 24: Tonelagem e teor médio dos resultados da classificação de recursos minerais para os diferentes intervalos de incerteza.</i>	89
<i>Tabela 25: Estatísticas descritivas das realizações resultantes da simulação sequencial gaussiana no campo gaussiano.</i>	107
<i>Tabela 26: Estatísticas descritivas das realizações resultantes da simulação sequencial gaussiana após a transformação inversa.</i>	110
<i>Tabela 27: Estatísticas de 50.057 observações de 484 depósitos minerais.</i>	112

1. Introdução

Padrões Internacionais de Declaração de Recursos e Reservas Minerais foram criados com o objetivo de proteger o investidor e garantir transparência aos empreendimentos de mineração. Esses padrões foram se desenvolvendo de acordo com a necessidade de cada país e se mostraram cada vez mais necessários após notórios casos de fraudes, que catalizaram a criação e o aperfeiçoamento de regras para a classificação e declaração de recursos e reservas minerais, além de estimular a aceitação internacional das mesmas, garantindo a segurança necessária para que ações de companhias de mineração fossem negociadas internacionalmente.

Os principais guias internacionais de declaração de recursos e reservas minerais, como por exemplo o Guia CBRR Para Declaração de Resultados de Exploração, Recursos e Reservas Minerais (CBRR, 2016), são baseados em princípios de competência, materialidade e transparência com a finalidade de garantir que a declaração pública seja feita por especialistas da forma mais transparente possível a partir de informações provenientes de materiais em quantidade e qualidade suficiente para dar credibilidade aos resultados obtidos. Desta forma, estes guias requerem que os recursos minerais sejam classificados em medido, indicado e inferido de acordo com o grau de confiança e conhecimento geológico e que o procedimento utilizado para a classificação seja descrito detalhadamente. Este tipo de classificação pode ser baseado em diferentes fatores como, por exemplo, a distância entre furos de sondagem, a variância de krigagem, modelos de incerteza, entre outros.

Para que haja transparência nas informações de declaração de recursos e reservas minerais, a avaliação de incertezas é imprescindível, visto que os valores estimados no cálculo de recursos e reservas de um depósito mineral apresentam variações em relação aos valores reais. Deste modo, conhecer as incertezas é importante também do ponto de vista econômico, porque a partir de sua quantificação os possíveis cenários de distribuição de teores podem ser previstos e utilizados para embasar a análise de riscos de investimentos.

Atualmente existem diferentes abordagens bastante utilizadas para acessar as incertezas presentes na estimativa de recursos minerais, tais como a Variância de Krigagem (Royle, 1977; Sabourin 1984; Froidevaux, Roscoe e Valiant, 1986), Variância de Interpolação (Yamamoto, 2000), Erro Relativo da Krigagem (Blackwell,

1998), entre outros. Porém, são técnicas baseadas na estimativa por krigagem, que apresenta a suavização dos resultados, ou seja, valores muito altos são subestimados e valores muito baixos são superestimados.

A simulação condicional é um dos métodos geoestatísticos que vêm ganhando popularidade na indústria mineral internacional, pois possibilita a construção de diferentes modelos equiprováveis que reproduzem de forma eficiente a variabilidade do depósito mineral, permitindo assim acessar as incertezas presentes em estimativas para fins de classificação de recursos minerais e otimização de malhas de sondagem. Este crescimento no uso de técnicas de simulação condicional, em parte, se deve ao desenvolvimento tecnológico que vêm permitindo utilizar algoritmos mais complexos com tempo de processamento cada vez menor, o que não era viável a algumas décadas atrás.

A combinação de técnicas de simulação condicional e intervalos de confiança da média mostra-se a tendência atual para classificação de recursos minerais e o grau de confiança utilizado pode variar de acordo com cada caso específico.

Neste trabalho a metodologia de classificação de recursos minerais baseada na quantificação de incerteza é aplicada à tipologia Sulfeto Disseminado do corpo de minério Sequeirinho, parte do Depósito de Óxido de Ferro-Cobre-Ouro Sossego (Carajás – PA). O modelo de incerteza é derivado de realizações calculadas por Simulação Sequencial Gaussiana, onde são calculados os intervalos de confiança de 90% para a quantificação da incerteza de estimativa presente em cada bloco. Obtidas as incertezas, estas são utilizadas como parâmetros de definição das classes de recursos minerais de acordo com padrões internacionais de declaração de recursos e reservas minerais.

2. Objetivos

Levando em consideração o crescente uso das técnicas de simulação condicional e as recomendações dos padrões internacionais de Declaração de Recursos Minerais para a avaliação de incertezas, pretende-se neste trabalho derivar curvas de probabilidade de ocorrência de teores em blocos de minério a partir dos resultados da simulação condicional e então calcular o intervalo de confiança da média para quantificar a incerteza de cada bloco. A incerteza, calculada por meio do

erro padrão da média, será o parâmetro utilizado para classificar blocos de minério de acordo com as classes propostas pelo Comitê Internacional de Declaração de Recursos e Reservas Minerais (CRIRSCO, 2013) e adotadas pela CBRR (2016).

3. Revisão da Literatura

3.1 Estatística

3.1.1 Distribuição de Frequências

Segundo Yamamoto, Bettencourt e Montanheiro (2001), é recomendável que se faça a análise estatística a partir da composição de furos de sonda com o objetivo de caracterizar e descrever estatisticamente as distribuições dos dados buscando o melhor entendimento do comportamento das variáveis de interesse dentro do depósito. A partir desta análise, determina-se o teor médio e a distribuição de frequência dos teores.

A distribuição de frequências é a etapa inicial da análise estatística. Esta é construída tabulando-se os dados da característica medida do depósito em intervalos constantes (Yamamoto, Bettencourt e Montanheiro, 2001), como por exemplo, o teor. A Figura 1 apresenta um exemplo de histograma, onde a altura de cada coluna representa o número de observações para o correspondente intervalo x .

Figura 1: Exemplo de distribuição de frequência, onde a altura de cada coluna representa o número de observações para o correspondente intervalo x .

Fonte: Borradaile (2003).

De acordo com Borradaile (2003), os resultados de muitos processos físicos e observações geológicas resultam em uma distribuição de frequência muito similar à Distribuição Normal. Essa distribuição requer uma propriedade física (x) cujo o valor pode variar entre $-\infty$ e $+\infty$ com os valores de x mostrando uma forte tendência de agrupamento em torno da média ($\bar{x}$). A dispersão em torno da média é definida pela variância (σ^2) ou pelo desvio padrão (σ). A curva Gaussiana apresenta a forma de um sino e é simétrica com o decaimento exponencial de seus flancos dado pela equação (Borradaile, 2003):

$$y = ce^{-ax^2} \quad (1)$$

onde $c > 0$, $a > 0$ são constantes e a curva apresenta um pico com valor $y = c$, localizado em $x = 0$. Os pontos de inflexão marcam a mudança de curvatura de convexo para côncavo e ocorre em $x = \pm(2a)^{-\frac{1}{2}}$. Segundo Borradaile (2003), esses pontos são importantes pistas visuais em qualquer distribuição natural pois identificam graficamente o desvio padrão (σ) (Figura 2).

Figura 2: Valores específicos de z em unidades de desvio padrão (σ) que abrangem certas percentagens de observações simetricamente em torno da média

Fonte: Borradaile (2003)

Para distribuições que aderem estritamente ao modelo teórico de uma distribuição normal, a probabilidade de ocorrência de um dado valor de x pode ser predita precisamente (Borradaile, 2003), sendo que a validade das estatísticas baseadas em uma distribuição Normal depende de quão próxima a distribuição natural está da distribuição teórica.

De acordo com Yamamoto, Bettencourt e Montanheiro (2001) a distribuição lognormal é bastante encontrada em problemas de avaliação de reservas e é caracterizada por assimetria positiva com muitos valores baixos e poucos valores altos.

Como pode ser observado em Koch e Link (1971) a fórmula da distribuição lognormal é dada por:

$$f(X) = \frac{1}{w\beta\sqrt{2\pi}} \exp \left[-\frac{1}{2\beta^2} (\ln w - \alpha)^2 \right] \quad (2)$$

sendo α e β^2 são, respectivamente, a média e a variância do logaritmo natural da observação w . A média de w é dada por

$$\mu = e^{\alpha + 1/2\beta^2} \quad (3)$$

e a variância de w por:

$$\sigma^2 = \mu^2 (e^{\beta^2} - 1) \quad (4)$$

De acordo com Journal (1989), função densidade de probabilidade da distribuição lognormal é positivamente assimétrica com uma longa cauda de valores altos de baixa probabilidade de ocorrência (Figura 3) e segundo Koch e Link (1971), o grau de assimetria depende somente do valor de β^2 . Y

3.1.2 Estatística Descritiva

A estatística descritiva é utilizada na etapa inicial da análise, em um primeiro contato com os dados e, segundo Magalhães e De Lima (2002), é um conjunto de

técnicas utilizadas para descrever e resumir os dados, para que conclusões a respeito de suas características possam ser feitas.

Figura 3: Esboço de distribuição lognormal

Fonte: Journal (1989)

A partir do conhecimento da distribuição de frequências dos dados, algumas estatísticas permitem estudar as propriedades da população em termos do valor médio medido e como os demais se distribuem em torno desse valor (Yamamoto, Bettencourt e Montanheiro, 2001).

A média é uma medida de tendência central dos dados, ou seja, o valor esperado para a distribuição e é calculada como:

$$E[X] = \sum_{i=1}^n X_i P(X_i) \quad (5)$$

onde $P(X_i)$ é a probabilidade associada à ocorrência da i -ésima variável X .

Esta expressão também pode ser escrita de forma simplificada, onde se assume que as probabilidades associadas às n variáveis aleatórias são iguais entre si, ou seja, iguais a $1/n$ e, deste modo, a média será calculada por:

$$E[X] = \bar{X} = \sum_{i=1}^n X_i \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n X_i \quad (6)$$

Segundo Spiegel (1967), a variância mede a dispersão dos valores em torno da média e é determinada como:

$$Var[X] = E[X^2] - E[X]^2 = S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 P X_i \quad (7)$$

ou

$$S^2 = \frac{1}{n} \sum_{i=1}^n [X_i - \bar{X}]^2 \quad (8)$$

O desvio padrão (S) é dado pela raiz quadrada da variância e é expresso na mesma unidade e grandeza dos valores originais.

Quando os valores de S tendem a se concentrar próximos da média a dispersão é pequena, mas se os valores tendem a se afastar da média, a dispersão é grande (Figura 4)

Assimetria é a medida do grau de simetria de uma distribuição de frequências em torno da média. Pode ser positiva, se a cauda da distribuição estiver à direita da média e negativa, se a cauda da distribuição estiver à esquerda da média.

O coeficiente de variação é a razão entre o desvio padrão e a média,

$$CV = \frac{S}{\bar{X}} \quad (9)$$

e, de acordo com Koch & Link (1971), esta estatística pode ser utilizada para comparar a variabilidade natural de depósitos minerais, pois é bastante informativa, visto que relaciona a média e a variância e é adimensional.

Figura 4: Representação de diferentes tamanhos de variâncias

Fonte: Spiegel (1967).

3.1.3 Teorema do Limite Central

Segundo Davis (2002) o teorema do limite central diz que se um conjunto de amostras for retirado de uma população e suas médias forem calculadas, distribuição destas médias tende a uma distribuição normal, sendo que a tendência para a normalidade se torna mais pronunciada para amostras maiores.

Sejam $X_1, X_2, \dots$ variáveis aleatórias independentes, identicamente distribuídas e com média μ e variância σ^2 . Então, se

$$S_n = X_1 + X_2 + \dots + X_n \quad (n = 1, 2, \dots), \quad (10)$$

$$\lim_{n \rightarrow \infty} P\left(a \leq \frac{S_n - n\mu}{\sigma\sqrt{n}} \leq b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{u^2}{2}} du \quad (11)$$

isto é, a variável aleatória $\frac{S_n - n\mu}{\sigma\sqrt{n}}$, que é a variável aleatória correspondente a S_n é assintoticamente normal (Spiegel, 1967).

De acordo com Spiegel (1967), o teorema também é válido sob condições mais gerais, quando, por exemplo, $X_1, X_2, \dots$, são variáveis aleatórias independentes com a mesma média e a mesma variância, mas não necessariamente com a mesma distribuição.

O Teorema do Limite Central nos permite formular testes estatísticos baseados na distribuição normal e aplicá-los mesmo em circunstâncias onde a população amostrada não é normalmente distribuída (Davis, 2002).

Segundo Magalhães e De Lima (2002), em situações práticas, onde o interesse reside na média amostral, esse teorema permite utilizar a distribuição Normal para estudar $\bar{X}$ probabilisticamente.

3.1.4 Intervalo de Confiança da Média

O intervalo de confiança é o intervalo de valores plausíveis que um parâmetro de uma população pode assumir, baseado no valor da estatística que estima esse parâmetro. Ele é construído de maneira que o verdadeiro valor do parâmetro em questão estará contido no intervalo com probabilidade específica. A largura do

intervalo de confiança transmite a informação sobre o quão precisamente o valor do parâmetro pode ser estimado (Davis, 2002).

O intervalo de confiança para a média pode ser construído a partir do erro padrão da média, que descreve a variação das estimativas da média que são esperadas caso amostras sejam tomadas repetidamente.

Um intervalo de confiança de 95%, por exemplo, implica que se o processo de estimativa for repetido diversas vezes, espera-se que 95% dos intervalos calculados contenham o valor do parâmetro estudado (Everitt & Skrondal, 2002)

Como pode ser observado em Yamamoto, Bettencourt e Montanheiro (2001), o intervalo de confiança da média pode ser calculado a partir da estatística t :

$$t = \frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}} \quad (12)$$

onde, $\bar{X}$ é média amostral e a μ média populacional.

Para o nível de confiança 90%, a expressão seria, por exemplo:

$$\bar{X} - t_{5\%} \frac{s}{\sqrt{n}} < \mu < \bar{X} + t_{5\%} \frac{s}{\sqrt{n}} \quad (13)$$

Sendo que a expressão t é simétrica e depende do número de graus de liberdade, que no caso da estimativa da média é igual a $n - 1$ (n = número de amostras). Quando o número de graus de liberdade tende ao infinito, a distribuição t tende à distribuição normal (Yamamoto, Bettencourt e Montanheiro, 2001).

De acordo com Borradaile (2003) a estatística t é utilizada para $n < 30$. Para valores de $n \geq 30$ deve-se utilizar a estatística z . Desta forma para um intervalo de confiança de 90% a expressão é dada por:

$$\bar{X} - z_{5\%} \frac{s}{\sqrt{n}} < \mu < \bar{X} + z_{5\%} \frac{s}{\sqrt{n}} \quad (14)$$

Seguindo a mesma premissa o erro padrão da média é calculado segundo a seguinte fórmula:

$$Erro = z \frac{\sigma}{\sqrt{n}} \quad (15)$$

3.2 Geoestatística

A geoestatística oferece uma forma de descrever a continuidade espacial, que é uma característica essencial de muitos fenômenos naturais (Isaaks & Srivastava, 1989).

De acordo com Yamamoto (2001), a análise geoestatística é a etapa fundamental da avaliação de reservas por métodos geoestatísticos, sendo que é a partir dela que é obtido o variograma, que expressa a variabilidade natural do depósito.

3.2.1 Variáveis Regionalizadas

Como destacado em Yamamoto (2001), as variáveis regionalizadas são variáveis dependentes de sua localização, ou seja, representam os valores das variáveis referenciadas geograficamente e foram introduzidas por Matheron (1965) com o objetivo de descrever quantitativamente variações espaciais em corpos de minérios.

Segundo Journé & Huijbregts (1978) um fenômeno mineralizado pode ser caracterizado pela distribuição espacial de um certo número de quantidades mensuráveis denominadas variáveis regionalizadas, que podem ser, por exemplo, a distribuição de teores em um espaço tridimensional, a distribuição da espessura de uma camada de sedimentos e até mesmo a distribuição do preço de mercado de um metal no tempo.

Todas as observações quantitativas (geofísicas, geoquímicas, sedimentológicas, etc.) feitas em duas ou três dimensões podem ser consideradas variáveis regionalizadas (Yamamoto, 2001).

As variáveis regionalizadas apresentam uma característica “aleatória” e uma característica “estrutural”. A primeira é responsável pelas irregularidades e variação imprevisível de um ponto a outro e a segunda, pelas relações existentes entre os pontos no espaço (Landim, 2006).

Yamamoto (2001) afirma que a Teoria das Variáveis Regionalizadas objetiva estudar a representação das propriedades estruturais das variáveis regionalizadas visando a resolução de problemas de estimativa e que esta teoria possui um conceito básico chamado hipótese intrínseca que implica que uma função descreve o comportamento da variável regionalizada no espaço e que esta função é uma

característica intrínseca da regionalização. A função intrínseca é o chamado semivariograma e a variação é estacionária se ela existir em todas as partes do espaço. Desta forma, o variograma deve ser o mesmo e qualquer parte que seja amostrada (Yamamoto, 2001).

3.2.2 Variograma

Segundo Landim (2006), as ferramentas fundamentais dos métodos geoestatísticos no estudo do comportamento das variáveis regionalizadas são o variograma e a krigagem. De acordo com Yamamoto (2001), a função variograma $2\gamma(h)$ descreve o comportamento espacial da variável regionalizada e é definida como:

$$2\gamma(h) = \frac{1}{n} \sum_{i=1}^n [Z(x+h) - Z(x)]^2 \quad (16)$$

ou seja, é igual a esperança matemática do quadrado da diferença entre os valores de pontos no espaço, separados por uma distância (h) .

A função semivariograma $\gamma(h)$, utilizada no estudo das variáveis regionalizadas, é metade da função Variograma $2\gamma(h)$, mas a literatura usualmente se refere à função $\gamma(h)$ como variograma:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n [Z(x+h) - Z(x)]^2 \quad (17)$$

Yamamoto (2001) descreve o desenvolvimento matemático necessário para que seja possível expressar a função variograma em termos da variância $C(0)$:

$$\gamma(h) = C(0) - C(h) \quad (18)$$

Graficamente, a função variograma é representada pelo variograma e, segundo Yamamoto (2001), as suas principais propriedades de um variograma com patamar típico são: amplitude, patamar, efeito pepita e variância espacial (Figura 5).

A amplitude reflete o grau de homogeneização entre as amostras. Quanto maior for a amplitude, maior será homogeneidade entre as amostras. Patamar é o

valor da variância no qual o variograma estabiliza-se, efeito pepita é o valor da função variograma próximo à origem e variância espacial é dada pela diferença entre a variância *a priori* e o efeito pepita.

O ajuste de uma função matemática do variograma por uma função matemática prédefinida do variograma experimental é feita a partir dos parâmetros principais do variograma (amplitude, patamar, efeito pepita e variância espacial) e é conhecido na geoestatística como ajuste de modelo teórico.

Figura 5: Variograma com patamar típico e suas propriedades

Fonte: Yamamoto (2001)

3.2.3 Validação Cruzada

A validação cruzada é utilizada para validar a eficiência do modelo de variograma e também dos parâmetros de vizinhança que serão utilizados na krigagem, por isso, deve ser feita antes da estimativa.

De acordo com Armstrong (1998), diferentes modelos de variograma podem ser ajustados a um variograma experimental e a validação cruzada pode ser utilizada para saber qual desses modelos é o adequado.

O processo consiste em retirar, temporariamente, um ponto amostrado do conjunto de dados e estimar o valor desse ponto por krigagem a partir das amostras localizadas na vizinhança. Repetindo-se este procedimento para todos os pontos amostrados, são obtidos os erros da estimativa para cada ponto (Armstrong, 1998).

3.2.4 Anisotropias

Anisotropia é a mudança de comportamento de um fenômeno espacial conforme a direção e como pode ser observado em Yamamoto (2001), a anisotropia pode ser geométrica quando o patamar é constante e a amplitude varia conforme as direções; zonal quando o patamar varia de acordo com a direção e a amplitude permanece constante; e mista quando tanto o patamar quanto a amplitude variam de acordo com diferentes direções (Figura 6).

Figura 6: Tipos de Anisotropias.

Fonte: Yamamoto (2001)

3.2.5 Krigagem Ordinária

De acordo com Landim (2006), Krigagem é a estimativa de valores de variáveis distribuídas no espaço, e/ou no tempo, a partir de valores adjacentes, que apresentam interdependência expressa pelo variograma.

Deutsch (2002) descreve o estimador da krigagem simples como:

$$z^*(x_0) - m_0 = \sum_{i=1}^n \lambda_i [z(x_i) - m_i] \quad (19)$$

onde $z^*(x_0)$ é o valor no ponto estimado; m_0 é a média populacional; λ_i , o peso que as amostras recebem na estimativa; $z(x_i)$ é o valor das amostras usadas na estimativa e m_i é a média associada aos locais amostrados.

Para minimizar o erro da estimativa, a medida do erro é dada por:

$$E[(Z^* - Z_0)^2] \quad (20)$$

Para minimizar este erro utiliza-se a constante λ_0 e os pesos λ_i (Chilés & Delfiner, 1999), sendo que a relação entre os pesos e a média amostral é descrita por:

$$\lambda_0 = m_0 - \sum_{i=1}^n \lambda_i m_i \quad (21)$$

Tomando como premissa que média amostral é igual a média populacional, o estimador da krigagem pode ser escrito como apresentado por Chilés & Delfiner (1999):

$$z^*(x) = \sum_{i=1}^n \lambda_i z(x_i) + \lambda_0 \quad (22)$$

A krigagem ordinária apresenta erro de variância mínimo e não necessita que a média populacional seja conhecida. A variância da estimativa da krigagem ordinária é minimizada sob a condição de que a soma dos pesos seja igual a 1. Esta é também conhecida como condição de não viés da krigagem ordinária segundo Yamamoto (2001):

$$\sum_{i=1}^n \lambda_i = 1 \quad (23)$$

O estimador da krigagem ordinária pode ser calculado por:

$$z_{ko}^*(x_0) = \sum_{i=1}^n \lambda_i z(x_i) \quad (24)$$

onde os ponderadores ($\lambda_i, i = 1, \dots, n$) são obtidos como resultado do sistema de equações de krigagem, que pode ser representado por um sistema de equações lineares que expresse em notação matricial, é:

$$\begin{bmatrix} \gamma(x_1, x_1) & \cdots & \gamma(x_1, x_n) & 1 \\ \vdots & \ddots & \vdots & \vdots \\ \gamma(x_n, x_1) & \cdots & \gamma(x_n, x_n) & 1 \\ 1 & \cdots & 1 & 0 \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \bar{\gamma}(x_1, x_0) \\ \vdots \\ \bar{\gamma}(x_n, x_0) \\ 1 \end{bmatrix} \quad (25)$$

onde μ é o multiplicador de Lagrange.

3.2.6 Krigagem Indicadora

A Krigagem Indicadora foi introduzida por Journel (1983) e de acordo com Revuelta (2017) é a principal técnica geoestatística não linear utilizada na indústria mineral.

Por meio da transformação das variáveis de interesse em 0 e 1, a krigagem indicadora pode ser utilizada para variáveis categóricas, para indicar a ausência ou presença de determinada característica (litologia, zona mineralizada, etc.), ou para variáveis contínuas, para representar diferentes intervalos de teores, por exemplo.

De acordo com Deutsch (2002) a krigagem indicadora é a utilização do método de krigagem (simples ou ordinária) para estimar uma variável previamente transformada em indicadora. Segundo o mesmo autor, o objetivo do formalismo de indicadoras para variáveis contínuas é estimar diretamente a distribuição de incertezas $F_Z(x)$ em um local não amostrado (x).

De acordo com Rivoirard (1994), a partir da suposição de que uma variável aleatória $z(x)$ pode apresentar um número de valores finitos, por exemplo, $z(x) = 0, \text{ ou } 1, \text{ ou } 2, \text{ ou } 3$, numa determinada localidade x . Os possíveis valores a serem atribuídos para a localidade x podem ser codificados como funções indicadoras. Se $Z(x) = i$, a indicadora $I(Z(x) = i)$ será igual a 1, caso contrário, igual a 0.

A codificação indicadora de variáveis contínuas para o local (x) é descrita por Journel (1983), como:

$$i(x; z) = \text{Prob} \{z(x) \leq z\} \quad (26)$$

$$= \begin{cases} 1, & \text{se } z(x) \leq z \\ 0, & \text{caso contrário} \end{cases}$$

Para variáveis categóricas utiliza-se (Soares, 2006):

$$i(x; z) = \begin{cases} 0, & \text{se } z(x) \neq \text{tipo } k \\ 1, & \text{se } z(x) = \text{tipo } k \end{cases} \quad (27)$$

onde k é o número de tipos de uma variável categórica.

3.2.7 Krigagem Simples

Segundo Armstrong (1998), krigagem simples é um método de interpolação geoestatística onde a média das variáveis regionalizadas é conhecida. Essa é a principal diferença entre esta e a krigagem ordinária.

De acordo com Davis (2002) a krigagem simples se baseia em três premissas: (1) As observações são uma realização parcial de uma função aleatória $Z(x)$, onde x denota a localização espacial; (2) a função aleatória é estacionária de segunda ordem, portanto a média, a covariância espacial e a semivariância não dependem de x ; (3) a média é conhecida. A premissa (3) parece limitar a aplicabilidade da krigagem simples, porém existem diversas circunstâncias onde a média é conhecida previamente. Por exemplo, se a variável que está sendo mapeada foi transformada, a média de uma variável transformada é zero. Se a variável é constituída por resíduos de uma função ajustada por mínimos quadrados, a média também é zero.

Segundo Armstrong (1998) a krigagem simples é utilizada em grandes minas na África do Sul, onde a média de cada área é conhecida porque a região vem sendo minerada há muitos anos.

Considerando uma variável regionalizada $Y(x)$ com média igual a 0, a variável regionalizada inicial é obtida de $Z(x) = Y(x) + m$. Desta forma o estimador $Y(x)$ é dado por:

$$Y_x^*(x_0) = \sum_{i=1}^n \lambda_i' Y(x_i) \quad (28)$$

O estimador deve ser não enviesado e ter mínima variância. Para não ser enviesado, o valor do erro deve ser 0. Sendo assim,

$$E [Y_x^* - Y_x] = E \left[\sum_{i=1}^n \lambda_i' Y(x_i) - Y_x \right] = 0 \quad (29)$$

Como a média é 0, não existe condição para a soma dos pesos, pois este estimador é automaticamente não enviesado. A variância do erro de estimativa é:

$$\text{Var} [Y_x^* - Y_x] = E \left[\sum \lambda_i' Y(x_i) - Y_x \right]^2 \quad (30)$$

Como não há condição para a soma dos pesos o multiplicador de Lagrange não é necessário e o sistema de krigagem é apenas:

$$\begin{bmatrix} \gamma(x_1, x_1) & \cdots & \gamma(x_1, x_n) \\ \vdots & \ddots & \vdots \\ \gamma(x_n, x_1) & \cdots & \gamma(x_n, x_n) \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_n \end{bmatrix} = \begin{bmatrix} \bar{\gamma}(x_1, x_0) \\ \vdots \\ \bar{\gamma}(x_n, x_0) \end{bmatrix} \quad (31)$$

Segundo Goovaerts (1997) a variância da krigagem simples é dada por:

$$\sigma_{sk}^2 = \text{cov}(x_0, x_i) - \sum_{i=1}^n \lambda_i \text{cov}(x_i, x_i) \quad (32)$$

3.2.8 Simulação Condicional Geoestatística

A simulação condicional geoestatística reúne um conjunto de métodos geoestatísticos que podem ser usadas para gerar representações igualmente prováveis da variabilidade de um corpo de minério (Dimitrakopoulos, 1998). É dita condicional pois os valores nas localidades amostradas são mantidos nas realizações geradas, ou seja, é condicionada pelos pontos amostrados. Quanto maior o número de pontos amostrados, mais próximo da realidade é o resultado da simulação (Lantuéjoul, 2002).

Segundo Leuangthong, McLennan e Deutsch (2004) um modelo de incerteza pode ser produzido a partir de um conjunto de valores reproduzidos no espaço, onde um conjunto de possíveis resultados são referidos como uma realização.

Na Simulação Condicional geram-se modelos de incerteza a partir de um conjunto de realizações simuladas e essa incerteza é melhor descrita quando um grande número de realizações é produzido, porém um número relativamente pequeno, em torno de 100 de realizações, pode ser suficiente para descrever a incerteza (Rossi e Deutsch, 2014).

A simulação reproduz a variabilidade original dos dados e permite uma avaliação de incerteza (Rossi e Deutsch, 2014). Os valores extremos da distribuição original são preservados, já que os histogramas são reproduzidos e a variabilidade espacial é mantida. O modelo simulado deve representar corretamente as proporções de altos e baixos valores, a média, a variância, e outras características estatísticas dos dados. Além disso deve também reproduzir corretamente a continuidade espacial da variável, incluindo anisotropias, efeito pepita e outras características do variograma modelado.

De acordo com Leuangthong, McLennan e Deutsch (2004), um modelo simulado deve reproduzir:

- (1) Os valores dos dados em sua localidade
- (2) A distribuição do atributo de interesse
- (3) A continuidade espacial caracterizada pelo modelo de variograma

3.2.9 Simulação Sequencial Gaussiana

De acordo com Deutsch (2002), a simulação sequencial gaussiana se tornou o algoritmo mais popular para modelagem de variáveis contínuas devido a sua simplicidade aliada à sua efetividade em criar modelos numéricos que honram as estatísticas espaciais.

A aproximação permite encontrar o valor de uma variável $Z(x)$ a partir de sua distribuição condicional, dado o valor mais correlacionado ao mesmo local x . O princípio da simulação sequencial é a generalização da seguinte ideia: o condicionamento é estendido para incluir todos os dados disponíveis dentro de uma vizinhança de x , incluindo os dados originais e todos os valores previamente simulados (Deutsch e Journel, 1998).

A simulação sequencial gaussiana segue os seguintes passos:

1. A distribuição de dados originais é transformada para uma distribuição gaussiana com média 0 e variância 1;

2. Define-se um padrão aleatório de visitas a cada nó do grid;
3. A krigagem simples é usada com o modelo de variograma da variável transformada para determinar parâmetros (média e variância) da função da densidade acumulada condicional da função aleatória $Z(x)$;
4. Sortear aleatoriamente um valor simulado $Z^{(l)}(x)$ da função da densidade acumulada condicional;
5. Adicionar o valor simulado $Z^{(l)}(x)$ a base de dados;
6. Prosseguir para o próximo nó e repetir os passos de 3 a 6 até que todos os nós tenham sido simulados.

3.3 Transformação de dados

Para muitas técnicas geoestatísticas como, por exemplo, krigagem multigaussiana, krigagem lognormal, simulação sequencial gaussiana, entre outras, a transformação de dados é necessária. Segundo Yamamoto e Landim (2013) a transformação de dados pode ser feita por meio de funções lineares ou não lineares.

3.3.1 Transformação Gaussiana

Segundo Rossi e Deutsch (2014), a geoestatística moderna faz extensivo uso das distribuições Gaussianas devido a sua tratabilidade e as suas propriedades estatísticas convenientes.

O método mais simples de transformação de dados para uma distribuição Gaussiana é a transformação direta de quantil para quantil ou transformação por *Normal Scores* (NS), onde a função de distribuição acumulada de cada distribuição é utilizada para realizar a transformação (Figura 7).

A transformação por Normal Score é dada pela transformação do quantil:

$$y = G^{-1}(F(z)) \quad (33)$$

e pode ser inversamente transformada por

$$z = F^{-1}(G(y)) \quad (34)$$

A transformação por normal score preserva a posição e é reversível. A desvantagem é que picos de valores constantes na distribuição original podem causar problemas.

Figura 7: Transformação Gaussiana por meio da função de distribuição acumulada

Fonte: Rossi & Deutsch (2014).

3.3.2 Verificação de Multigaussianidade

De acordo com Yamamoto e Chao (2009) para se utilizar métodos que exigem a transformação dos dados para distribuição Gaussiana é necessário testar se a distribuição de dois, três ou mais pontos é Gaussiana.

Segundo Rossi e Deutsch (2014), devido a simplicidade em verificar a Gaussianidade de dois pontos em relação à verificação da mesma para três pontos ou mais, pode-se assumir a multi-Gaussianidade dos dados a partir da verificação entre dois pontos (bi-Gaussianidade).

Para Deutsch e Journal (1998), a condição necessária para bi-Gaussianidade é que a curva de distribuição da probabilidade para qualquer par de valores $Y(x), Y(x + h), \forall x, \forall h$, seja normal.

Em Cortes (2016) observa-se que a checagem de bi-Gaussianidade é feita pela razão *razão raiz quadrada do variograma / madograma*.

O madograma, segundo Deutsch e Journal (1998) é similar ao variograma tradicional, porém ao invés do quadrado da diferença entre dois pontos amostrados, é dado o valor absoluto entre eles:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n |Z(x+h) - Z(x)| \quad (35)$$

3.4 Erro e Incertezas

3.4.1 Erro

O erro é definido como a diferença entre o valor obtido por um processo de medição e o valor verdadeiro da grandeza medida (JCGM, 2008).

Segundo Isaaks & Srisvastava (1989) o erro só pode ser calculado a partir do conhecimento do valor real (desconhecido), sendo assim o erro da estimativa é dado por:

$$\text{erro} = \text{valor estimado} - \text{valor real} \quad (36)$$

Espera-se que a estimativa resulte em um valor muito próximo ao valor verdadeiro, porém seja qual for o método escolhido, sempre haverá algum erro. Dada a impossibilidade de calcular exatamente o erro, recorre-se ao cálculo da incerteza, considerada uma indicação da magnitude do erro (Isaaks e Srisvastava, 1989).

De acordo com Dominy, Noppé e Annels (2002), um erro de estimativa de 10% é comum e, geralmente, aceitável em uma operação de mina subterrânea. Mas segundo os mesmos autores existem alguns casos onde o erro calculado após a reconciliação varia entre 50% e 80%. As consequências dos erros e a falta de entendimento sobre as incertezas pode levar a resultados desastrosos.

3.4.2 Incerteza e fontes de incerteza em investigações geológicas

Segundo Caers (2003), a incerteza é causada pelo entendimento incompleto do que se deseja quantificar. Quantificar algo que não se conhece por inteiro pode ser uma tarefa subjetiva, que não pode ser testada contra uma verdade irrefutável.

Segundo a definição proposta por Zimmerman (2000), a incerteza implica que em uma determinada situação uma pessoa não dispõe de informações apropriadas para descrever, prescrever ou prever deterministicamente e numericamente um sistema, seu comportamento ou outra característica.

De acordo com Isaaks & Srisvastava (1989), não existe uma incerteza correta, pois não há como saber se a quantificação da incerteza está realmente correta ou se é a melhor possível.

Mann (1993) ressalta que, na análise detalhada de um processo geológico específico, é possível identificar inúmeras fontes de incerteza que não podem ser medidas individualmente e isso justifica estimar a incerteza total. Segundo Mann (1993), uma única fonte pode contribuir para diferentes tipos de incerteza.

De acordo com Mann (1993), existem três tipos de incerteza:

- As incertezas associadas a erros de medida e imprecisão dos métodos de medida;
- Incertezas inerentes às variações naturais devido à diferentes propriedades físicas em regiões espaciais distintas
- Incertezas advindas da falta de informação ou ignorância científica.

De acordo com Bárdossy e Fodor (2004), no âmbito de investigações geológicas, observa-se que as incertezas apresentam duas fontes principais: erros advindos da variabilidade natural do fenômeno estudado e erros humanos. Desta forma, Bárdossy e Fodor (2004) afirmam que em geologia a incerteza pode ser classificada em dois tipos principais:

- Incerteza devido a variabilidade natural;
- Incerteza devido a incompetência e imperfeições humanas.

A variabilidade natural pode ser quantificada e descrita, mas não é possível reduzi-la; os erros humanos podem ser atenuados, mas não podem ser completamente eliminados. Uma forma de lidar com estes tipos de erro é quantificar e estimar a incerteza por meio de cálculos e análises subjetivas. Mesmo assim, isso não é suficiente para identificar e determinar as incertezas de cada variável separadamente, mas para abordagens geológicas o cálculo da incerteza total é necessário (Bárdossy e Fodor, 2004).

Em termos de incerteza proveniente da variabilidade natural, as principais fontes estão relacionadas a heterogeneidade, uma propriedade natural de processos e objetos geológicos. A heterogeneidade pode ser medida pelo grau de variabilidade e, geralmente, quanto maior for a heterogeneidade, maior será a incerteza (Bárdossy e Fodor, 2004).

As principais fontes de incerteza devido ao erro humano podem ocorrer em todas as fases de investigação geológica, são elas o conhecimento incompleto do

objeto ou de um determinado processo geológico, deficiências na modelagem, aplicação imprecisa de métodos matemáticos, aspectos financeiros, econômicos e limitações naturais ou temporais da investigação (Bárdossy e Fodor, 2004). Essas fontes de incerteza podem ocorrer ao longo de todas as fases de investigação geológica e, segundo Bárdossy e Fodor (2004), elas devem ser discutidas exaustivamente pois representam grande parte da incerteza total presente em uma investigação geológica.

Uma discussão detalhada sobre as fontes de incerteza e as consequências de falhas no tratamento dos erros e da incerteza é apresentada por Dominy, Noppé e Annels (2002).

3.4.3 Modelos de Incerteza

Segundo Caers (2003), qualquer avaliação de incerteza necessita ser baseada em algum tipo de modelo, e qualquer modelo, estatístico ou definido fisicamente, deve apresentar suas premissas implícitas ou explícitas, calibrações e escolhas de dados, entre outros ajustes que são subjetivos. Desta forma, conclui que não há uma incerteza verdadeira, e sim modelos de incerteza.

De acordo com Bárdossy e Fodor (2004), o modelo de incerteza expressa o desvio de um dado modelo em relação a realidade natural e o nível de detalhe dos modelos geológicos podem ser diferentes dependendo do nível de complexidade do sistema geológico estudados. Os modelos geológicos se tornam mais complexos quanto mais detalhes são adicionados a eles e, desta forma, os modelos de incerteza refletem esse aumento na complexidade.

3.5 Classificação de Recursos Minerais

A declaração pública de recursos minerais estimados requer que esses recursos sejam classificados em medido, indicado e inferido de acordo com graus de confiança. Essa classificação reflete diferentes níveis de confiança geológica e diferentes graus de avaliação técnico-econômica (Miskelly, 2003). A Figura 8 ilustra de maneira simplificada a relação entre a classificação de recursos e reservas e o nível de conhecimento geológico e confiança das informações.

Figura 8: Quadro ilustrativo da classificação de Recursos e Reservas Minerais.

Fonte: CBRR (2016).

Diferentes normas para classificação de recursos e reservas são utilizadas em diferentes países. A criação dessas normas, ou códigos, visa garantir proteção ao investidor e transparência ao empreendimento mineiro, além de evitar diferentes tipos de fraudes (Rossi e Deutsch, 2014). Os principais códigos internacionais, ou NRO's (national reporting organisations) como são conhecidos, são o JORC (Joint Ore Reserves Committee) utilizado na Australásia (AUSIMM, 1999); o NI 43-101 (National Instrument 43-101) no Canadá (CIM, 2011); o SME Guide for Reporting Exploration Results, Mineral Resources, and Mineral Reserves (SME, 2017) nos Estados Unidos; o South African Code for the Reporting of Exploration Results, Mineral Resources and Mineral Reserves (SAMREC, 2016) na África do Sul e o Pan-European Union e o United Kingdom's Reporting Code na Europa (PERC, 2013).

3.5.1 Metodologias de Classificação de Recursos Minerais por meio da quantificação da incerteza

Os métodos utilizados para classificar os Recursos minerais de acordo com as categorias propostas pelos códigos internacionais baseiam-se na quantidade e no nível de confiança dos dados. O aumento desses dois fatores é diretamente relacionado ao aumento no nível de conhecimento geológico.

De acordo com Dohm (2005), muitos elementos afetam a confiança em um recurso estimado e entre os principais estão a confiabilidade do modelo geológico, a continuidade da mineralização, a configuração da malha de amostragem, a qualidade dos dados amostrados, e a confiança do método de avaliação.

Os códigos internacionais de declaração de Recursos e Reservas minerais incentivam a quantificação de incerteza sempre que for possível, porém não sugerem que seja utilizado um método específico. Segundo Rossi e Deutsch (2014) todos os códigos de Declaração de Recursos e Reservas sugerem a utilização de alguma forma de descrição estatística das incertezas, porém não explicitam como esta avaliação deve ser elaborada. Esta decisão é atribuída à pessoa competente, sendo que, desta forma, a escolha do melhor método de avaliação de incertezas vai depender da experiência prévia deste profissional em determinado bem mineral.

A classificação de Recursos Minerais por meio de incertezas pode ser feita por métodos baseados em krigagem ordinária como, por exemplo, variância de krigagem, variância relativa de krigagem, variância de interpolação, entre outros. Porém métodos baseados na krigagem não levam em consideração a incerteza local e são baseados em sua maioria na distância entre as amostras.

Segundo Dohm (2005), a variabilidade em realizações provenientes de simulações pode ser interpretada para acessar a incerteza presente em estimativas de recursos minerais. Além disso trata-se de um modo rápido para obter um espectro de possíveis visões sobre as estatísticas globais e também das características do corpo de minério.

De acordo com Rossi e Deutsch (2014) o uso de realizações para obter intervalos probabilísticos para a classificação de recursos minerais ainda não é um método difundido e a probabilidade, utilizada para definir os recursos medidos, indicados e inferidos, depende da prática adotada pela companhia de mineração.

Emery, Ortiz e Rodríguez (2006) ressaltam que a quantificação de incerteza por meio de simulações condicionais requer atenção em três pontos:

1. Os dados disponíveis devem ser representativos de todo o depósito.
2. O modelo geoestatístico utilizado para simular os teores deve descrever com precisão a distribuição espacial dos dados. Se necessário o depósito deve ser dividido em diferentes domínios com distribuição homogênea de teores.

3. Os limites da zona que será simulada devem ser claramente definidos pela geologia, economia e por considerações que sejam relevantes em relação a lavra.

A abordagem mais comum encontrada na literatura atual para a classificação de recursos minerais a partir de um modelo probabilístico, que pode ser gerado a partir de simulação condicional, se dá por meio da utilização de intervalos de confiança onde são estabelecidos limites de valores aceitáveis de incerteza a um dado nível de confiança para cada classe de recurso mineral.

O intervalo de confiança da média é uma forma bastante utilizada para quantificar a incerteza. Intervalos de confiança muito altos com, por exemplo, de 99% e de 99.5 % são bastante utilizados em ciências médicas e biológicas, mas segundo Wellmer (1998), estas situações não são realísticas para geologia, onde os níveis de confiança utilizados variam principalmente entre 90 e 95%.

Isaaks e Srivastava (1989) dizem que o intervalo de confiança de 95% é um padrão comumente utilizado para reportar a incerteza, pois se refere a aproximadamente 2 vezes o desvio padrão. Porém intervalos de confiança de 84% a 95% também são encontrados na bibliografia referente a classificação de recursos minerais (Wellmer, 1998).

Um método de classificação bastante aplicado e discutido atualmente (Dohm, 2005; Rossi e Deutch, 2014; Silva e Boisvert, 2014; Abzalov, 2016) é o método baseado em incertezas aplicado a períodos de produção. Segundo Silva e Boisvert (2014), para este método de classificação, os parâmetros críticos que devem ser definidos são: volume a ser classificado, precisão, e o intervalo de confiança. Desta forma é comum encontrar intervalos em que a precisão varia entre 10% e 30% e os intervalos de confiança variam entre 95% e 80%.

Dohm (2005) utiliza, para um período de produção de um mês, um limite de 15% para o intervalo de confiança de 90%.

Rossi e Deutsch (2014) dizem que para o período de 1 trimestre, tipicamente, o recurso mineral é classificado como medido quando apresenta uma variação de $\pm 15\%$ em 90% das vezes; para recurso mineral indicado a incerteza varia $\pm 30\%$ em 90% das vezes; e recurso mineral inferido apresenta variação entre $\pm 30\%$ e $\pm 100\%$, também 90% das vezes. Quando a incerteza é maior que 100% o material não é classificado como recurso.

Silva e Boisvert (2014) afirmam que para definir blocos medidos em um mesmo período de produção é utilizada a precisão de $\pm 15\%$, com 95% de confiança; e para classificar blocos indicados utilizou-se $\pm 30\%$ em um intervalo de de confiança de 80%.

3.5.2 Histórico e Desenvolvimento dos Códigos Internacionais de Declaração de Recursos e Reservas Minerais

Padrões internacionais de declaração de recursos e reservas vêm sendo amplamente discutidos e propostos de forma concreta desde a década de 1980, porém propostas que desejavam criar regras para que bens minerais fossem declarados e classificados sistemicamente são tratadas desde 1909, quando o engenheiro de minas norte americano Herbert Hoover publicou “Principles of Mining” onde recomendava a divisão de reservas em provada, provável e prospectivas (Miskelly, 2003).

Em 1980 o *United States Bureau of Mines* e o *United States Geological Service* (USGS) publicaram a Circular 831 “Principles of a Resource/Reserve Classification for Minerals”, que, pela primeira vez, apresentou uma divisão entre Recursos e Reservas minerais (Miskelly, 2003).

A necessidade de regras claras e objetivas para declarações públicas de ativos minerais cresceu após casos de fraudes envolvendo empreendimentos mineiros que apresentavam estimativas fraudulentas de suas reservas minerais e conseguiam angariar investimentos e, conseqüentemente, a valorização de seus ativos.

Entre as ocorrências internacionalmente famosas figura o “Caso Poseidon” (segunda metade da década 1960), que em um contexto econômico de altos preços de níquel, a companhia australiana de exploração mineral Poseidon NL fez a maior descoberta de níquel em *Windarra (Western Australia)*, o que gerou uma capitalização de \$700 milhões mesmo com teores baixos e custo de operação alto. O resultado foi uma bolha econômica conhecida como “*The Poseidon Bubble*” (Simon, 2003) causada pela crescente negociação de ações de uma companhia de mineração mesmo com a falta de informações sólidas sobre a viabilidade do empreendimento. De acordo com Miskelly (2003), isso impulsionou o Governo Australiano e os órgãos reguladores a desenvolver padrões mais apropriados para declaração a partir da criação de um comitê conhecido como *Joint Ore Reserves Committee* (JORC) que em 1989 publicou

a primeira versão do JORC, o código australiano para declaração de recursos e reservas desde então aceito pela *Australian Stock Exchange* (ASX).

O escândalo “BRE-X” (1997), que apresentava declarações fraudulentas do que viria a ser o maior depósito de ouro já descoberto (Busang Gold, Indonésia) (Revuelta, 2017) também teve um papel importante em relação ao desenvolvimento de padrões de declaração pública de recursos minerais. A partir desta ocorrência houve a intensificação nos trabalhos que definiram novas regras para garantir que as declarações de recursos e reservas atingissem um nível de maior transparência possível aos investidores. Apesar de reconhecido que mesmo com as regulamentações criadas após o caso BRE-X, a fraude cometida não teria sido parada, os esforços para a criação de novos padrões de declaração resultaram em um documento publicado em 1999 por uma força tarefa (*Mining Standards Task Force*) criada pelas agências regulatórias canadenses, o “*Setting New Standards, Recommendations for Public Mineral Exploration and Mining Companies*” (Miskelly, 2003).

Em 1993 o CMMI (*Council of Mining and Metallurgical Institutions*) estabeleceu um grupo de trabalho (CMMI Group) para definições de recursos e reservas (Resources/Reserves International Definitions Working Group), com representantes da Austrália (AusIMM), Canada (CIM), South Africa (SAIMM), do Reino Unido (IMM) e Estados Unidos (SME) com o objetivo de criar um padrão de definições internacionais para declaração pública de Resultados de Exploração, Recurso e Reservas Minerais baseado no Jorc Code. Esse grupo se reuniu sob o nome Combined Reserves International Reporting Standards Committee (CRIRSCO) pela primeira vez no 15º CMMI Congress na África do Sul em 1994 e após anos de negociações foi firmado em Denver (1997) um acordo (*The Denver Accord*) que criava as duas grandes categorias de classificação utilizadas até os dias de hoje: Recursos Minerais e Reservas Minerais, juntamente com suas subcategorias, Recurso Medido, Indicado e Inferido e Reservas Provadas e Prováveis (Figura 8).

Ainda no final dos anos 1990, também impulsionados pelos casos de fraude relacionados a declaração de recursos e reservas, Austrália, Estados Unidos, Canadá, África do Sul e Reino Unido revisaram seus padrões de declaração existentes e um trabalho em conjunto com as Nações Unidas (*United Nations Economic Commission for Europe*) resultou em uma aceitação das mesmas definições (Miskelly, 2003).

Em 1999 o Jorc Code foi atualizado, seguido pelos também internacionalmente reconhecidos códigos vigentes na África do Sul.

De maneira geral os principais códigos internacionais como o JORC utilizado na Australásia; o NI 43-101 no Canadá; o *SME Guide for Reporting Exploration Results, Mineral Resources, and Mineral Reserves* nos Estados Unidos; e o SAMREC na África do Sul, passaram por modificações ao longo dos anos, mas permanecem com definições similares. As atualizações dos códigos internacionais continuam acontecendo, sendo o JORC uma das principais referências devido ao seu importante papel no histórico de desenvolvimento de padrões para regulamentar as declarações de recursos e reservas minerais.

Atualmente, o Combined Reserves International Reporting Standards Committee é conhecido como Comitê For Mineral Reserves International Reporting Standards (CRIRSCO), estabelecido com esse novo nome em 2002, atua como um grupo que atualmente congrega organizações que são responsáveis pelo desenvolvimento de códigos e guias de declaração de recursos e reservas na Australasia (JORC), Brasil (CBRR), Colômbia (CCRR), Canadá (CIM), Chile (Comitê Nacional), Europa (PERC), Cazaquistão (KAZRC), Mongólia (MPIGM), Rússia (NAEN), Turquia (UMREC), Indonésia (KOMBERS _ KCMI), África do Sul (SAMREC) e Estados Unidos (SME) (Figura 7). Segundo Henley e Allington (2013), o valor das companhias listadas nas bolsas de valores desses países contam com mais de 80% do capital listado pela indústria mineral.

Em 2003 o CRIRSCO concordou em produzir um Modelo Internacional para Declaração de Recursos e Reservas Minerais, o que foi concretizado em 2006 com a publicação do *International Reporting Template* (IRT), um documento guia que é utilizado como apoio para os países que já possuem um modelo de declaração e que visa assistir países ou regiões que ainda não possuem um código de declaração ou que necessitam de atualizações no código vigente. De acordo com CRIRSCO (2013), sua mais recente atualização, o documento funciona com um modelo para o desenvolvimento de um código e não como um código propriamente dito. Atualmente, as organizações (NRO's) representadas pelo CRIRSCO estão de acordo e seguem os princípios do IRT, sendo que os modelos de declaração de recursos de reservas dessas organizações apresentam 90% de similaridade com o IRT. A Figura 9 mostra os países e/ou regiões que fazem parte do CRIRSCO atualmente.

Figura 9: Países membros do CRIRSCO em Julho de 2018.

Fonte: CRIRSCO (2018)

No Brasil, a Comissão Brasileira de Recursos e Reserva (CBRR) foi estabelecida em 2015 como uma iniciativa de três grandes instituições representativas do setor mineral brasileiro: Associação Brasileira de Empresas de Pesquisa Mineral (ABPM), Agência Brasileira de Desenvolvimento Tecnológico da Indústria Mineral (ADIMB) e o Instituto Brasileiro de Mineração (IBRAM). No mesmo ano a CBRR assinou um memorando de entendimento com o CRIRSCO, passando assim a ser uma organização membro deste Comitê.

O Guia CBRR (2016) apresenta termos alinhados às definições padrões encontrados na edição mais recente do CRIRSCO (2013).

3.5.3 Classificação de Recursos minerais: CRIRSCO (2013)

De acordo com CRIRSCO (2013) as principais definições encontradas no *template* são idênticas ou não materialmente diferentes das definições utilizadas nos países representados por esse Comitê, entre eles, o Brasil. Abaixo são apresentadas as definições de Recurso Mineral e das categorias nas quais estes recursos devem ser classificados de acordo com CRIRSCO (2013):

- **Recurso Mineral:** é a concentração ou ocorrência de material sólido de interesse econômico no interior ou na crosta terrestre de tal forma, teor ou qualidade e quantidade que existam perspectivas razoáveis para uma eventual extração econômica
- **Recurso Mineral Inferido:** é a parte do Recurso Mineral para qual a quantidade e teor ou qualidade são estimadas com base em evidência geológica e amostragem limitadas.
- **Recurso Mineral indicado:** é a parte do Recurso Mineral para qual a quantidade, teor ou qualidade, densidades, forma e características físicas são estimadas com confiança suficiente para permitir a aplicação de Fatores Modificadores com detalhes suficientes para apoiar o planejamento da mina e avaliação da viabilidade econômica do depósito.
- **Recurso mineral Medido:** Um Recurso Mineral Medido é a parte de um Recurso Mineral para a qual quantidade, grau ou qualidade, densidades, forma e características físicas são estimadas com confiança suficiente para permitir a aplicação de Fatores Modificadores para apoiar o planejamento detalhado da mina e a avaliação final da viabilidade econômica do depósito.

O guia de declaração publicado pelo CRIRSCO (2013) deve ser utilizado como um roteiro que determina que tipo de informação deve estar contida em uma declaração de recursos e reservas minerais. Além de apresentar algumas definições, este documento aborda critérios importantes que devem ser adotados em cada etapa da Avaliação de Recursos e Reservas Minerais e explica o que deve ser discutido no relatório de Declaração de Recursos e Reservas Minerais.

Os princípios que regem o funcionamento e a aplicação do Modelo são Transparência, Materialidade e Competência:

- O princípio da **Materialidade** exige que um Relatório Público apresente todas as informações relevantes que os investidores e seus consultores profissionais exigiriam e esperam encontrar em um Relatório Público, com o propósito de fazer um julgamento ponderado e equilibrado com relação aos Resultados de Exploração, Recursos Minerais ou Minerais.

- A **Transparência** exige que o leitor de um Relatório Público receba informações suficientes, com apresentação que seja clara e inequívoca, de modo a compreender o relatório e a não ser induzido em erro.
- O Princípio da **Competência** exige que o Relatório Público seja baseado em trabalho que é de responsabilidade de pessoas adequadamente qualificadas e experientes, sujeitas a um código profissional de ética e regras de conduta.

Dentro do princípio da Competência destaca-se a figura da Pessoa Competente, definido como um profissional do setor de mineração (registrado junto em uma NRO) com processos disciplinares executáveis, incluindo os poderes para suspender ou expulsar um membro. Este profissional deve ter no mínimo cinco anos de experiência relevante no tipo de mineralização ou tipo de depósito em consideração e na atividade que essa pessoa está realizando (CRIRSCO, 2013).

A este profissional são atribuídas decisões chave no processo de avaliação de recursos minerais como, por exemplo, a escolha do método de estimativa e classificação de Recursos Minerais. De acordo com as boas práticas e sugestões apresentadas pelo padrão CRIRSCO (2013) a Pessoa Competente possui competência para escolher o método que julgar mais adequado para determinado bem mineral ou depósito e deve estar preparada para demonstrar, perante a seus pares, suas competências em determinado bem mineral.

3.6 Contexto Geológico da Área de Estudo

Os dados utilizados neste trabalho são provenientes de campanhas de sondagem realizadas com o intuito de interceptar o corpo de minério Sequeirinho, que está inserido no contexto do depósito de óxido de Ferro-Cobre-Ouro Sossego da Província Mineral Carajás, uma das províncias minerais mais importantes do planeta.

A Província Mineral Carajás destaca-se pelo seu notável potencial metalogenético e por hospedar depósitos minerais de classe mundial, entre eles depósitos gigantes de minério de Ferro de Alto Teor, a maior quantidade de depósitos de óxido de Ferro-Cobre-Ouro de classe mundial do planeta e um dos raros exemplares de depósito de Ouro e EGP (Elementos do Grupo da Platina) representado por Serra Pelada. Na mesma província também há a presença de

depósitos cupro-auríferos sem associação com óxidos de Ferro, depósitos manganésíferos sedimentares, depósitos de Cromo e Níquel-EGP associados a intrusões maficas-ultramáficas acamadadas, depósitos lateríticos de Bauxita, Níquel e Ouro, todos de grande importância econômica (Monteiro et al., 2014).

3.6.1 Depósito de óxido de Ferro-Cobre-Ouro Sossego

O Depósito de óxido de Fe-Cu-Au Sossego, localiza-se no município de Canaã dos Carajás, Estado do Pará, Brasil. Atualmente é explorado pela VALE S.A., representa um depósito de classe mundial e o primeiro depósito desse tipo a entrar em produção na Província Mineral de Carajás. Este depósito compreende dois grandes corpos de minério principais, Sossego e Sequeirinho (Figura 10). Ambos estão localizados ao longo de uma zona de cisalhamento regional de direção WNW–ESSE que define o contato entre as unidades metavulcanossedimentares do Supergrupo Itacaiúnas, a norte, e os gnaisses e migmatitos do Complexo Xingu a sul (Augusto et al., 2008).

Segundo Monteiro et al. (2008a) os padrões de alteração hidrotermal encontrados no corpo de minério Sequeirinho remetem a uma formação em níveis crustais mais profundos enquanto os padrões de alteração hidrotermal presentes no corpo de minério Sossego são características de níveis crustais intermediários a rasos. O Corpo Sossego apresenta idade de 1,6 Ga e o Corpo Sequeirinho apresenta idade de 2,6 Ga, e está relacionada a processos deformacionais ao longo de zonas de cisalhamento regionais (Neves, 2006).

3.6.1.1 Corpo de Minério Sequeirinho

O Corpo de Minério Sequeirinho é hospedado por granito, gabro e rochas metavulcânicas félsicas que contêm lentes de rochas ultramáficas metamorfizadas. De acordo com Monteiro et al. (2008a), estas rochas são fortemente afetadas por alteração hidrotermal sódica e cálcico-sódica com ferro-endenita/hastingsita, controladas por fraturas. Há substituição dos corpos de granito e gabro por uma assembleia de alteração sódico-cálcicas, que são superimpostas por uma assembleia cálcio-sódica sustentada por actinolita, que é predominante neste corpo. Essas zonas de alteração sódico-cálcicas são espacialmente associadas a corpos maciços de

magnetita que parecem substituir as rochas metavulcânicas félsicas, gabros e granitos. Esses corpos de magnetita formam corpos subverticais paralelos a falha que controla o corpo de minério e são cortados por estreitas zonas de alteração potássica pobremente desenvolvida, onde se localizam as mineralizações de cobre e ouro (Figura 11). Os sulfetos estão associados a zonas de stockwork com cristais grossos de actinolita, magnetita e apatita que formam corpos brechados de alto mergulho. A assembleia de sulfetos é dominada por calcopirita com ocorrência secundária de pirita e minerais de níquel (Monteiro et al, 2008a).

Figura 10: (A) Mapa geológico simplificado da região do Complexo de Mineração Sossego (modificado de VALE por Monteiro et al., 2008a).

Fonte: Monteiro et al.(2008a).

O decapeamento da Cava Sequeirinho (Figura 12) teve início em 2002 e a produção em 2004, a previsão é que a cava final apresenta 500 metros de profundidade (Golder Associates, 2010).

Figura 11: Seção esquemática do corpo de minério Sequeirinho.

Fonte: Monteiro *et al* (2008a)

Figura 12: Vista aérea da Cava Sequeirinho.

Fonte: Golder Associates (2010)

4. Materiais e Métodos

O método de classificação de recursos minerais utilizado neste trabalho foi aplicado a base de dados fornecida pela Vale S.A. composta por furos de sondagem da Mina de Cobre do Sossego, Cava Sequeirinho, localizada no município de Canaã dos Carajás, no estado do Pará, Brasil.

De acordo com Freitas (2015) a capacidade de movimentação da mina é de 70 MT/a e produção de 15 MT/a de ROM (*Run of Mine*).

4.1 Base de dados

O banco de dados utilizado neste trabalho é composto por três planilhas no formato texto separado por vírgulas (extensão .csv) com informações básicas dos testemunhos dos 298 furos de sonda:

- Header: código do furo (BHID), coordenadas UTM (Leste, Norte e cota) da boca dos furos de sondagem, profundidade máxima atingida e ano de execução;
- Survey: informações sobre profundidade (AT), azimuth (BRG) e mergulho (DIP) ao longo dos furos;
- Assay: informações de profundidade, zonas mineralizadas e teores de Cu (%).

O mapa base de sondagens é apresentado na Figura 51 do ANEXO B.

4.1.1 Modelo de blocos

O modelo de blocos é uma representação computacional de um depósito mineral onde as zonas geológicas ou de interesse (mineralização, descontinuidades geotécnicas) são definidas e preenchidas por blocos que são associados a valores de teor estimados. Trata-se de um modelo numérico e gráfico de onde se pode retirar informações importantes para o entendimento estrutural e composicional de um depósito mineral (Duke e Hanna, 2014).

Duke e Hanna (2014) ressaltam que o modelo de blocos é uma representação do modelo geológico conceitual do depósito, mas é de extrema importância dado que os modelos de recursos minerais, bem como a análise risco de um depósito mineral, são derivados desse modelo.

No presente trabalho utilizou-se um modelo de blocos com dimensões de 10 metros nos eixos X e Y e 16 metros no eixo Z, escolhidas com base nas necessidades de planejamento de longo prazo do depósito. O modelo foi construído a partir de uma malha regular de forma a englobar toda a área do depósito, resultando em 1.008.000 blocos. Entre estes foram selecionados apenas os blocos contidos no volume ocupado pelo corpo mineralizado em Sulfeto Disseminado (modelado por krigagem indicadora) e, somente estes blocos foram utilizados para as análises estatísticas e geoestatística realizadas neste trabalho.

4.2 Validação da Base de dados

O banco de dados utilizado apresenta dois litotipos referentes a mineralização de cobre: Sulfeto Disseminado e Brecha Sulfetada. Este trabalho foi desenvolvido sobre o litotipo Sulfeto Disseminado que, apesar de apresentar teores mais baixos que o minério contido em brecha, possui maior volume e continuidade.

A base de dados foi validada com o objetivo de conferir se as informações contidas nas três planilhas do banco de dados (Header, Survey e Assay) estavam completas e se correlacionavam quanto ao comprimento do furo, intervalos amostrais e localização dos dados. Buscou-se também por identificar intervalos sobrepostos (*overlaps*) e trechos com falta de informação (*gaps*). Os erros encontrados foram corrigidos de forma que todas as informações presentes nas planilhas pudessem ser utilizadas sem prejuízo nas etapas seguintes do trabalho.

Após a validação os dados foram importados para o software Isatis® uma única planilha (formato .dm) que serviu de base para as análises apresentadas a seguir.

4.2.1 Modelo do Corpo de Minério

Apesar da envoltória de teores gerada neste trabalho não apresentar avaliação econômica para a definição de minério, adotou-se o termo corpo de minério Sequeirinho para se referir a envoltória de teores de Sulfeto Disseminado, onde as análises geoestatística foram desenvolvidas.

O corpo de minério Sequeirinho foi modelado por meio de krigagem de variáveis indicadoras. De acordo com Duke e Hanna (2014), a real vantagem de utilizar métodos computacionais na etapa de modelagem é a combinação de estatística e geoestatística com interpretação geológica para criar um modelo válido do depósito, ou seja, que apresente características estruturais muito próximas da realidade.

4.3 Métodos

Neste trabalho a incerteza é o parâmetro utilizado para a classificação de recursos minerais. Esta é derivada dos resultados de Simulação Sequencial

Gaussiana, método de simulação condicional escolhido para simular os teores de cobre. A simulação foi calculada em 100 realizações.

A incerteza foi quantificada a partir do intervalo de confiança da média das 100 realizações da simulação, em cada bloco do modelo, ao nível de confiança de 90%. O erro padrão da média, calculado para os resultados, ainda no campo Gaussiano. Esse erro foi convertido em percentual do valor calculado por krigagem ordinária, conforme:

$$Incerteza = \left[\frac{z \frac{\sigma}{\sqrt{n}}}{KO} \right] * 100\% \quad (37)$$

Apresenta-se na Figura 13 o fluxograma das principais etapas para a aplicação do método de trabalho proposto.

Para a classificação utilizou-se os intervalos de incerteza adaptados de Rossi e Deutsch (2014):

- Recurso Mineral Medido: incerteza entre 0 e 15% calculada para um nível de confiança de 90%
- Recurso Mineral Indicado: incerteza entre 15% e 30% calculada para um nível de confiança de 90%
- Recurso Mineral Inferido: Incerteza entre 30% e 100% calculada para um nível de confiança de 90%

Blocos com mais de 100% de incerteza não foram classificados como recurso mineral.

As etapas de validação de dados e demais processamentos utilizados nesta dissertação foram realizados nos programas de computador:

- R Core Team (2015): Validação da base de dados e cálculos (Volume e Tonelagem);
- Datamine Studio RM®: visualização dos dados;
- Isatis®: Análise estatística e Geoestatística, pósprocessamento dos resultados das simulações, cálculo do intervalo de confiança e classificação de recursos minerais.

5. Resultados e Discussão

5.1 Análise exploratória dos dados

Ao todo foram contabilizadas 49.721 amostras, incluindo todas as tipologias de minério (Brecha Sulfetada, Misto Lixiviação e Misto Flotação) e intervalos considerados de estéril. Os intervalos descritos como Sulfeto Disseminado totalizam o número de 20.268 amostras.

A Tabela 1 apresenta as estatísticas para todas as amostras presentes na base de dados (incluindo os litotipos Brecha Sulfetada, Misto Lixiviação e Misto Flotação) e a Tabela 2 apresenta as estatísticas somente para o litotipo Sulfeto Disseminado.

Tabela 1: Estatísticas descritivas dos dados de Cu (%) no depósito mineral.

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Desvio Padrão
49721	0,01	0,04	0,53	0,61	0,5	39,08	1,40

Fonte: Autor

Tabela 2: Estatísticas descritivas dos dados de Cu (%) para o Sulfeto Disseminado no depósito mineral.

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Desvio Padrão
20268	0,01	0,10	0,28	0,61	0,62	39,08	1,16

Fonte: Autor

Figura 13: Fluxograma que compreende as principais etapas da metodologia proposta.

Fonte: Autor

Figura 14: Histograma para a Variável Cu% no depósito mineral.

Fonte: Autor

Figura 15: Histograma para a Variável Cu% em amostras de Sulfeto disseminado no depósito mineral.

Fonte: Autor

A distribuição da variável Cu (%) considerando todos os litotipos (Figura 14) é lognormal assim como a distribuição de Cu (%) no Sulfeto Disseminado (Figura 15). As amostras descritas como Sulfeto Disseminado representam 40 % das amostras e

apresentam os mesmos valores de máximo (39,08%) e mínimo (0,01%) que os demais dados (Brecha Sulfetada, Misto Lixiviação e Misto Flotação).

A média das amostras de Sulfeto Disseminado (0,54%) é menor do que a média apresentada pelo total de amostras (0,61%), provavelmente devido aos altos teores observados na brecha sulfetada.

5.2 Regularização das amostras

A regularização das amostras foi feita para garantir que todas amostras apresentassem o mesmo suporte. Os furos de sonda apresentam amostras com espessuras que variam entre 0,07 e 4,20 m, que foram regularizadas para intervalos de 1 metro, a espessura mais frequente. Após a regularização houve o aumento do número de amostras de 16 % de modo que não houve mudanças significativas na média de teores e na soma de metal contido, o que valida o procedimento.

A estatísticas descritivas das amostras do corpo de minério, antes e após a regularização, são apresentadas nas Tabela 3 e Tabela 4. As distribuições das amostras regularizadas apresentam assimetria positiva para a variável cobre (Figura 16).

Figura 16: Distribuição da variável Cu (%) para amostras antes (A) e após (B) a regularização.

Fonte: Autor

O diagrama de dispersão de teores de cobre pelo comprimento das amostras regularizadas (Figura 18) mostra que a maior parte das amostras (bem como as amostras de teores mais altos) apresentam comprimento de 1 metro. Amostras com espessuras menores apresentam menor frequência e podem ser atribuídas a regiões de contato entre o corpo de minério e outros litotipos (Figura 17).

Tabela 3: Estatísticas dos dados de Cu (%) para o Sulfeto Disseminado no corpo de Minério

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Desvio Padrão
16631	0,01	0,10	0,29	0,61	0,64	39,08	1,18

Fonte: Autor

Tabela 4: Estatísticas dos dados de Cu (%) para o Sulfeto Disseminado no corpo de minério após a regularização.

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Desvio Padrão
19368	0,01	0,09	0,25	0,54	0,55	39,08	1,05

Fonte: Autor

Figura 17: Distribuição dos comprimentos (m) para amostras antes (A) e após (B) a regularização.

Fonte: Autor

Figura 18: Diagrama dos dados de Cu (%) versus comprimento das amostras regularizadas.

Fonte: Autor

5.3 Estimativa do corpo de minério por krigagem de variáveis indicadoras

O corpo de minério utilizado na simulação de teores foi modelado por krigagem de variáveis indicadoras. Os intervalos descritos como Sulfeto Disseminado foram selecionados e transformados em variáveis indicadoras. Foi criada a variável DISS e atribuiu-se o valor DISS = 1 para Sulfeto Disseminado e DISS=0 para os demais intervalos (estéril e outro tipo de mineralização). A distribuição dos dados transformados é apresentada na Figura 19.

Figura 19: Distribuição das variáveis após a transformação para indicadoras.

Fonte: Autor

5.3.1 Variogramas das variáveis indicadoras

A análise geoestatística foi realizada por análise exploratória. Desta forma foram calculados os variogramas experimentais para as direções $90^{\circ}/0^{\circ}$, $180^{\circ}/0^{\circ}$. e $0^{\circ}/90^{\circ}$. Os parâmetros utilizados para o cálculo do variograma experimental são apresentados na Tabela 5 e os parâmetros utilizados para o ajuste do modelo de variograma são apresentados na Tabela 6. Os variogramas experimentais e os modelos são apresentados na Figura 20.

Tabela 5: Parâmetros de cálculo do variograma experimental.

Direção	Passo	Número de Passos	Tolerância Angular	Tolerância na Distância
$90^{\circ}/0^{\circ}$	70	12	45°	35
$180^{\circ}/0^{\circ}$	80	5	45°	40
$0^{\circ}/90^{\circ}$	1	300	15°	0.5

Fonte: Autor

Tabela 6: Parâmetros de ajuste do modelo de variograma.

Modelo Esférico				
Estruturas	X (m)	Y (m)	Z (m)	Patamar
Efeito Pepita	-	-	-	0,02
1ª Estrutura	48,4	47,8	34,4	0,16
2ª Estrutura	178,2	163,4	188,3	0,06

Fonte: Autor

Figura 20: Variogramas experimentais e modelo teórico de variograma para a variável indicadora DISS.

Fonte: Autor

5.3.2 Krigagem ordinária de variáveis indicadoras

A krigagem de variáveis indicadoras foi calculada por krigagem ordinária e foram testados diferentes parâmetros de vizinhança. Os parâmetros de vizinhança utilizados são apresentados na Tabela 7.

Tabela 7: Parâmetros de busca para a krigagem indicadora.

Parâmetros	
Busca em X(m)	178
Busca em Y(m)	163
Busca em Z(m)	188
Número mínimo de amostras	2
Número de setores horizontais	4
Número ótimo de amostras por setor	4
Distância mínima entre 2 amostras	2

Fonte: Autor

O resultado da krigagem indicadora pode ser observado na Figura 21, onde as cores representam a probabilidade de ocorrência dos blocos serem compostos por Sulfeto Disseminado. Para este estudo, foi considerado como corpo de minério apenas o conjunto de blocos que apresentam probabilidade de ocorrência de Sulfeto Disseminado maior do que 50% (Figura 22).

A Figura 23 mostra o mapa de probabilidades do modelo de blocos de corpo de minério. Nota-se que os blocos com as maiores probabilidades de ocorrência da tipologia Sulfeto Disseminado localizam-se na região central do corpo de minério. Apesar do corte aplicado para definir os limites do corpo de minério ter sido a probabilidade de 50%, observa-se que a maior parte do modelo gerado por krigagem indicadora apresenta probabilidade maior de 70% de ocorrência de Sulfeto Disseminado.

A técnica de estimativa do corpo de minério de Sulfeto Disseminado por krigagem indicadora foi eficaz e comparando seus resultados ao mapa interpretado apresentado em Monteiro et al. (2008a), onde o corpo de minério Sequeirinho é representado por uma projeção da zona mineralizada em superfície, observa-se que as direções principais do corpo de minério foram preservadas assim como sua continuidade, como mostrado na Figura 24.

Figura 21: Modelo resultante da krigagem indicadora.

Fonte: Autor

Figura 22: Modelo resultante da krigagem indicadora com blocos com mais 50% de probabilidade de ocorrência de Sulfeto Disseminado.

Fonte: Autor

Figura 23: Contorno do corpo mineralizado preenchido por blocos do modelo probabilístico de ocorrência de Sulfeto Disseminado visto em planta (cota 48 m).

Fonte: Autor

Ressalta-se que a projeção apresentada por Monteiro et al. (2008a) apresenta a mineralização como um todo e no modelo gerado neste trabalho utilizou-se somente as amostras descritas como Sulfeto Disseminado, mas o primeiro pode ser utilizado para fins de validação visual visto que o Sulfeto Disseminado ocorre por toda a zona mineralizada do corpo de minério estudado.

5.4 Estimativa de teores por krigagem ordinária

5.4.1 Variogramas

A análise geoestatística foi realizada por análise exploratória e as direções 0°/60°, 270°/0° e 180°/30° (direção dos furos de sonda) foram escolhidas para o cálculo dos variogramas experimentais e posterior ajuste do modelo teórico do variograma, com os resultados interpretou-se que a anisotropia no domínio é mista. Apresentam-se na Tabela 8 os parâmetros de cálculo dos variogramas experimentais e na Tabela 9 são apresentados os parâmetros do modelo ajustado. A Figura 25

mostra a rotação utilizada na etapa de modelagem do variograma. O gráfico do variograma experimental e o respectivo modelo podem ser observados na Figura 26.

Figura 24: (A) Mapa geológico simplificado do depósito do sossego e seus corpos mineralizados (Monteiro et al., 2008a); (B) Corpo de minério Sequeirinho (Monteiro et al., 2008a); (C) Modelo do corpo de minérioSequeirinho construído por krigagem indicadora.

Fonte: Autor

Tabela 8: Parâmetros de cálculo do variograma experimental.

Direção		Passo	Número de Passos	Tolerância Angular	Tolerância na Distância
U	270°/0°	40	11	45°	20
V	180°/30°	1	150	15°	0,5
W	0°/60°	60	8	45°	30

Fonte: Autor

Figura 25: Elipsóide rotacionado de acordo com a anisotropia para Cu (%).

Fonte: Autor

Figura 26: Variogramas experimentais e modelo de variograma para a variável Cu(%).

Fonte: Autor

Tabela 9: Parâmetros de ajuste do modelo de variograma para Cu (%).

Estruturas	U (m)	Modelo Esférico		Patamar
		V (m)	W (m)	
Efeito Pepita	0.2	-	-	-
1ª Estrutura	75	80	9	0,7
2ª Estrutura	170	200	21	0.09
3ª Estrutura	270	250	-	0.08
4ª Estrutura	-	250	-	0.03

Fonte: Autor

5.4.2 Validação Cruzada

Validação Cruzada foi feita após a modelagem dos variogramas para a determinação dos melhores parâmetros de vizinhança para a krigagem ordinária. Os parâmetros de vizinhança escolhidos são apresentados na Tabela 10.

A Figura 27 apresenta o diagrama de dispersão entre os valores amostrais e estimados para a variável cobre, o coeficiente de correlação obtido foi de 0,59, que embora baixo foi considerado satisfatório haja vista que a variável é assimétrica positiva e o coeficiente de variação igual a 1,94.

Tabela 10: Parâmetros de vizinhança para a busca por amostras definidas na validação cruzada.

Parâmetros	
Busca em X(m)	270
Busca em Y(m)	250
Busca em Z(m)	21
Número mínimo de amostras	3
Número de setores horizontais	4
Número ótimo de amostras por setor	1
Número máximo de setores vazios	2

Fonte: Autor

5.4.3 Krigagem Ordinária

A krigagem ordinária foi realizada somente nos blocos situados no interior do corpo de minério definido para o litotipo Sulfeto Disseminado como apresentado em 5.4.2.

Os parâmetros de vizinhança utilizados para a krigagem ordinária são os parâmetros escolhidos apresentados em apresentados na Tabela 10 e os parâmetros de discretização de blocos na Tabela 11.

Figura 27: Diagrama de dispersão entre os valores amostrais e estimados para a variável cobre.

Fonte: Autor

As estatísticas descritivas dos resultados da krigagem ordinária podem ser observadas na Tabela 12 e o histograma dessa distribuição na Figura 28. A assimetria da distribuição amostral foi mantida nas estimativas, porém é evidente que estes resultados estão suavizados, pois o limite da distribuição é menor do que 15% de cobre. Essa suavização dos resultados é ainda mais evidente comparando-se as estatísticas descritivas dos resultados da krigagem à dos dados regularizados. Nessa comparação observa-se que não apenas o valor de máximo foi reduzido de 39,08%, na distribuição dos dados regularizados, para 12,52%, no resultado da krigagem ordinária, como também o desvio padrão, diminui de 1,05% para 0,56%, redução de praticamente 50%. A dispersão absoluta, quantificada pelo coeficiente de variação, também, corrobora com essa observação, foi reduzido de 1,94 para 1,10. A Figura 29 apresenta o modelo resultante da krigagem ordinária em três dimensões.

Tabela 11: Parâmetros para discretização de bloco.

Dimensões		Discretização
X	10	2
Y	10	2
Z	16	2

Fonte: Autor

Tabela 12: Estatísticas descritivas do modelo obtido pela krigagem ordinária.

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Desvio Padrão
78343	0,01	0,19	0,53	0,51	0,61	12,52	0,56

Fonte: Autor

Figura 28: Histograma dos dados obtidos por krigagem ordinária.

Figura 29: Modelo resultante de krigagem ordinária para Cu (%).

5.5 Simulação Condicional

5.5.1 Transformação dos dados

Para a realizar a simulação condicional é necessário transformar os dados de cobre (%), que apresentam uma distribuição assimétrica positiva, para uma distribuição normal padrão com média e variância conhecidas ($N[0,1]$). A técnica de utilizada foi a transformação por *normal score* (*nscore*). A Tabela 13 apresenta as estatísticas dos dados transformados e a Figura 30 mostra a distribuição dos teores de Cu (%) após a transformação.

Tabela 13: Estatísticas descritivas dos dados de Cu (%) transformados por *nscore*.

Nº de Amostras	Mínimo	1ºQuartil	Mediana	Média	3ºQuartil	Máximo	Variância
19368	-3,94	-0,67	0	0	0,67	3,94	1

Fonte: Autor

Após a transformação dos dados para a distribuição gaussiana, os resultados foram validados para garantir a hipótese de multigaussianidade. Para esta validação foi utilizada a razão *raiz quadrada de (variograma/madograma)*. A Figura 31 mostra o resultado positivo para o teste de multi-Gaussianidade, visto que os valores se aproximam de $\sqrt{\pi} = 1.772$ (linha pontilhada).

Figura 30: Distribuição dos dados de CU (%) transformados por *nscore*.

Fonte: Autor

Figura 31: Teste de bigaussianidade: raiz quadrada do variograma / madograma.

Fonte: Autor

5.5.2 Variogramas

A análise geoestatística foi iniciada pela análise exploratória, a partir da qual verificou-se que os dados transformados apresentam anisotropia mista, com direção de maior continuidade igual a 270°/0°. Desse modo, as direções escolhidas para o ajuste do modelo teórico de variograma foram 0°/60°, 270°/0° e 180°/30° (direção e mergulho dos furos de sonda).

Os parâmetros utilizados para o cálculo do variograma experimental são apresentados na Tabela 14 e os parâmetros utilizados para o ajuste do modelo teórico de variograma podem ser observados na Tabela 15. O variograma experimental e o respectivo modelo ajustado são apresentados na Figura 32.

Tabela 14: Parâmetros de cálculo do variograma experimental.

Direção	Passo	Número de Passos	Tolerância Angular	Tolerância na Distância
0°/60°	60	8	45°	30
180°/30°	1	150	15°	0,5
270°/0°	40	11	45°	20

Fonte: Autor

Tabela 15: Parâmetros de ajuste do modelo de variograma.

Estruturas	Modelo Esférico			
	X (m)	Y (m)	Z (m)	Patamar
Efeito Pepita	-	-	-	0,02
1ª Estrutura	75	70	12	0,6
2ª Estrutura	116	200	25	0,09
3ª Estrutura	270	250	-	0,14
5ª Estrutura	-	250	-	0,02

Fonte: autor

Figura 32: Variogramas experimentais e modelo de variograma para a variável Cu(%) transformada por nscore.

Fonte: Autor

5.5.3 Validação Cruzada

Após a modelagem de variogramas foi feita a Validação Cruzada. Esta etapa foi realizada diversas vezes até que se encontrassem os melhores parâmetros de vizinhança para a realização da krigagem simples. A Figura 33 apresenta o diagrama de dispersão entre os valores amostrais e estimados para a variável cobre transformados por *normal score*. Observa-se que a dispersão da nuvem de pontos concentra-se próxima à primeira bissetriz e o coeficiente de correlação de Pearson é igual a 0,73. Apresentam-se na Tabela 16 os valores dos parâmetros da validação cruzada escolhida.

Figura 33: Diagrama de dispersão entre os valores amostrais e estimados para a variável cobre transformados por normal score.

Fonte: Autor

Tabela 16: Parâmetros de busca para a Simulação Sequencial Gaussiana.

Parâmetros	
Busca em X(m)	270
Busca em Y(m)	250
Busca em Z(m)	25
Número mínimo de amostras	4
Número de setores horizontais	4
Número ótimo de amostras por setor	2
Distância mínima entre 2 amostras	2
Número ótimo de nós previamente simulados	4
Número aleatório (seed)	423141

Fonte: Autor

5.5.4 Simulação Sequencial Gaussiana

A Simulação Sequencial Gaussiana foi realizada somente nos blocos situados no interior do corpo de minério para o litotipo Sulfeto Disseminado definido no em 5.3. Optou-se por 100 simulações como discutido em 3.2.7.

Os parâmetros de vizinhança utilizados para a simulação sequencial gaussiana são apresentados na Tabela 16 e as estatísticas básicas de cada realização são apresentadas na Tabela 23 (ANEXO A).

A correção de suporte foi realizada após a simulação sequencial gaussiana, porque as amostras utilizadas e os blocos do modelo de blocos apresentam volumes diferentes. Essa correção foi calculada no Isatis® por meio da partição de blocos sem discretização conforme os parâmetros apresentados na Tabela 17.

Tabela 17: Parâmetros da Correção de Suporte.

Dimensões		Discretização
X	10	1
Y	10	1
Z	16	1

Fonte: Autor

Para realizar a correção de suporte calculou-se o variograma experimental para os dados de Cu (%) (não transformados) para as mesmas direções e parâmetros

apresentados na Tabela 14. Os parâmetros de ajuste do modelo são apresentados na Tabela 15.

As Figuras 34 e 35 apresentam a mesma realização, escolhida ao acaso, no campo Gaussiano e após a transformação inversa, respectivamente. As Tabelas 18 e 19 apresentam as estatísticas da realização tomada aleatoriamente e representadas nas Figuras 36 e 37.

Tabela 18: Estatísticas da realização número 15 no campo Gaussiano.

Realização	Blocos	Mínimo	Máximo	Média	Variância
15	84464	-4	4.18	-0.03	0.97

Fonte: Autor

Figura 34: Realização n° 15 resultante da simulação para teores de CU(%) no campo Gaussiano.

Fonte: Autor

Tabela 19: Estatísticas da realização número 15 após a transformação inversa.

Realização	Blocos	Mínimo	Máximo	Média	Variância
15	84464	0.01	39.08	0.51	0.99

Fonte: Autor

Figura 35: Realização n° 15 resultante da simulação para teores de CU(%) após a transformação inversa.

Fonte: Autor

A etapa de validação dos resultados de simulação consistiu em verificar se os modelos simulados reproduzem a distribuição de frequências e o variograma dos dados de entrada, bem como os valores da variável nos pontos amostrados. Esta etapa foi baseada nos procedimentos de validação de dados simulados discutidos por Leuangthong, McLennan e Deutsch (2004).

A primeira abordagem feita com o intuito de validar os modelos simulados foi a inspeção visual (em 3D) para checar a consistência dos modelos gerados, principalmente em relação às amostras utilizadas como condicionantes. Verificou-se com detalhe regiões de maior variabilidade, blocos atravessados por furos de sonda e as bordas do corpo de minério e afirma-se que os modelos simulados representam bem os detalhes relacionados a heterogeneidade dos dados de entrada e honram os valores nos locais amostrados.

Comparou-se as médias globais de cada realização com as médias dos dados e da krigagem ordinária (Figura 36). As médias das simulações variam entre 0,50 e 0,52 % de Cu, abaixo da média dos dados (0,54%) e variando em torno da média do resultado da krigagem ordinária (0,51%). Essas diferenças não são significativas e o resultado da simulação sequencial gaussiana foi considerado satisfatório para estes parâmetros.

Figura 36: Gráfico de validação das médias (Cu %) das realizações após a transformação inversa comparadas às médias dos dados e à média da krigagem ordinária.

Fonte: Autor

De acordo com Leuangthong, McLennan, e Deutsch (2004) deve ser feita a comparação dos histogramas das realizações com o histogramas dos dados de entrada como validação dos modelos simulados.

As distribuições da variável Cu (%) das realizações resultantes da simulação foi comparada à distribuição da mesma variável para os dados amostrais utilizados. A Figura 37 mostra distribuições de quatro realizações escolhidas ao acaso, e em comparação à distribuição dos dados amostrais (Figura 16 B) pode-se concluir que não existem diferenças significativas, ou seja, os resultados da simulação reproduzem o histograma dos dados de entrada.

Diagramas Quantil-Quantil (Q-Q) também podem ser uma boa indicação de que os modelos simulados reproduzem os histogramas dos dados de entrada. A Figura 38 apresenta diagramas Q-Q que comparam os quantis das mesmas realizações apresentadas na Figura 37 com os quantis da distribuição da variável Cu (%) dos dados de entrada e mostram ótima aderência entre as distribuições de forma que apenas os quantis superiores se distanciam da reta de referência devido aos *outliers* presentes nos dados.

Figura 37: Distribuição da variável Cu(%) nas realizações 5, 27, 76, 94 (escolhidas ao acaso).

Fonte: Autor

5.6 Cálculo de incerteza

O parâmetro de incerteza utilizado neste trabalho é proveniente do erro padrão da média (apresentado no item 3.1.4) e pode ser calculado para diferentes intervalos de confiança. Para este estudo optou-se pelo intervalo de confiança de 90% que, como discutido por Rossi e Deutsch (2014), é o intervalo mais comumente praticado na indústria para fins de classificação de recursos minerais. A incerteza, calculada sobre os modelos simulados foi definida como

$$Incerteza = \left[\frac{\text{erro padrão da média}(\text{realizações})}{KO} \right] * 100\% \quad (38)$$

onde o erro padrão da média representa a incerteza de cada bloco em relação ao teor obtido na estimativa de cada bloco por krigagem ordinária (KO).

Figura 38: Diagramas Quantil-Quantil (Q-Q) das realizações 5, 27, 76, 94 comparadas a distribuição de Cu (%) nos dados de entrada.

Fonte: Autor

5.7 Classificação de blocos

Como apresentado em 3.5.3 as formas atuais de classificação de recursos minerais propõem a classificação de blocos agrupados segundo determinado período de produção (anual e trimestral). Neste trabalho a classificação dos blocos foi feita para todos os blocos do modelo resultante da krigagem ordinária com teor de corte

acima de 0.33% de cobre, totalizando 40.086 blocos de minério (Figura 39). O teor de corte de 0.33% foi escolhido com base na Tabela 20, que apresenta diferentes teores de corte como estratégia para a vida útil da Cava Sequeirinho no período entre os anos 2011 a 2022. (Golder Associates, 2010).

Tabela 20: Teores de corte estratégicos entre os anos de 2011 e 2022.

Período	Teor de Corte
2011	0,33
2012	0,40
2013	0,40
2014	0,40
2015	0,40
2016	0,33
2017	0,33
2018	0,33
2019	0,33
2020	0,33
2021	0,33
2022	0,33

Fonte: Golder Associates (2010)

Figura 39: Blocos estimados por krigagem ordinária com teor maior do que o teor de corte de 0,33% de cobre.

Fonte: Autor

O critério de classificação utilizado neste trabalho foi discutido no item 4.3

Após classificar os recursos minerais, o volume de cada classe foi quantificado, assim como a quantidade de metal contido, que foi calculada como:

$$R = VDT \quad (39)$$

Onde R é o recurso mineral em tonelada de metal contido; V é o volume de cada bloco; D é a densidade aparente e T é o teor médio do bloco. Considerou-se como D a densidade aparente média do depósito mineral (2,85 g/cm³) fornecida pela companhia de mineração.

Apresentam-se na Tabela 21 os volumes totais e tonelagem de metal para cada classe de recursos minerais e nas Figuras 40 e 41, respectivamente, o modelo de blocos tridimensional com a distribuição espacial das classes e um diagrama de barras com o volume de cada classe.

Tabela 21: Resultado da classificação de recursos minerais em volume e em toneladas de metal contido.

Classe	Blocos	Volume (m ³)	Teor médio (%)	Tonelagem (T)
Medido	10.079	16.126.400	1,62	74.226.424
Indicado	16.881	27.009.600	0,67	51.264.624
Inferido	13.126	21.001.600	0,41	24.678.133

Fonte: Autor

Foram simulados 84.464 blocos e destes 40.086 apresentaram incerteza contida em um dos intervalos sugeridos para cada classe como sugerido por Rossi e Deutsch (2014). Destes, 10.079 blocos puderam ser classificados como recursos medidos; 16.881 blocos apresentaram incerteza compatível com recursos indicados, por fim, classificaram-se 13.126 blocos como recursos inferidos, todas as classes categorizadas a partir da incerteza calculada para o nível de confiança de 90%.

Em termos de quantidade de metal contido calculou-se:

- **Recurso Mineral Medido:** 74,2 MT de cobre a um teor médio de 1,62%;
- **Recurso Mineral Indicado:** 51,2 MT de cobre a um teor médio de 0,67%;
- **Recurso Mineral Inferido:** 24,6 MT de cobre a um teor médio de 0,41%.

Figura 40: Classes de recursos minerais em visualização 3D.

Fonte: Autor

Figura 41: Volume das classes de recursos minerais em metros cúbicos.

Fonte: Autor

Os intervalos de incerteza como parâmetro para classificação são comumente utilizados na indústria e discutidos na literatura, por exemplo Rossi e Deutsch (2014) e Silva e Boisvert (2014), mas não se encontrou em nenhum o valor ótimo de incerteza aceitável para definir cada classe de recursos minerais.

Os padrões internacionais de declaração de recursos e reservas minerais incentivam a utilização de incerteza como ferramenta para classificação e sugerem que o método de classificação seja descrito detalhadamente nos relatórios públicos,

porém não recomendam ou indicam quais valores devem ser utilizados, deixando esta decisão a cargo do profissional certificado como Pessoa Competente.

No Guia do Comitê Brasileiro de Declaração de Recursos e Reservas Minerais (CBRR, 2016), de modo similar aos guias de entidades regulamentadoras que fazem parte do CRIRSCO, lê-se que “*Para classificar um recurso como Medido ou Indicado, deve haver um nível razoavelmente elevado de confiança em relação à qualidade das informações utilizadas para estimar este recurso, bem como na interpretação dessas informações*”. Como se vê, o guia não faz referência a quais valores devem ser considerados na classificação.

5.8 Variação dos Intervalos de Incerteza

Para fins de comparação os intervalos de incerteza utilizados para a definição das classes de recursos minerais neste trabalho foram variados em 5% e 10% e duas novas classificações foram feitas de acordo com os parâmetros apresentados na Tabela 22. Os resultados dessa nova classificação e os resultados desta nova classificação são apresentados na Tabelas 23, onde são mostrados os volumes quantificados em cada classe e na Tabela 24 os recursos foram quantificados em tonelagem. A Figura 42 é o diagrama de barras onde se pode comparar os diferentes volumes quantificados.

Tabela 22: Parâmetros de incerteza utilizados para a classificação.

Classe	Intervalos de incerteza 1	Intervalos de incerteza 2	Intervalos de incerteza 3
Medido	0-15%	0-20%	0-25%
Indicado	15-30%	20-35%	25-40%
Inferido	30-100%	35-100%	40-100%

Fonte: Autor

O aumento de 5 pontos percentuais no intervalo de incerteza utilizado para definir recurso mineral medido eleva a quantidade de blocos medidos de 10.079 para 15.839, caracterizando aumento de 57% no volume desta classe de recurso mineral. Considerando o aumento de 10 pontos percentuais, o volume de blocos classificados como recursos medidos aumenta em 66%.

Figura 42: Variações do intervalos e incerteza para classificação de recursos minerais.

Fonte: Autor

Tabela 23: Volumes quantificados por classe com diferentes intervalos de incerteza.

Recurso Mineral	Intervalos de incerteza 1		Intervalos de incerteza 2		Intervalos de incerteza 3	
	Blocos	Volume	Blocos	Volume	Volume	Blocos
Medido	10.079	16.126.400	15.839	25.342.400	34.220.800	21.388
Indicado	16.881	27.009.600	15.993	25.588.800	22.817.600	14.261
Inferido	13.126	21.001.600	8.254	13.206.400	7.099.200	4.437

Fonte: Autor

Tabela 24: Tonelagem e teor médio dos resultados da classificação de recursos minerais para os diferentes intervalos de incerteza.

Classe	Intervalos de incerteza 1		Intervalos de incerteza 2		Intervalos de incerteza 3	
	Tonelagem	Teor médio	Tonelagem	Teor médio	Tonelagem	Teor médio
Medido	74.226.424	1,62%	95.674.615	1,32%	111.978.215	1,15%
Indicado	51.264.624	0,67%	40.031.249	0,55%	30.778.153	0,47%
Inferido	24.678.133	0,41%	14.463.317	0,38%	7.412.813	0,37%

Fonte: Autor

Para a classe de recurso mineral indicado o número de blocos classificados diminui quando a classificação é feita de acordo com os intervalos de incerteza 2 e 3. Para os intervalos de incerteza 2 e 3 são classificados, respectivamente, 15.993 e 14.261 blocos, uma diferença de 888 e 1.732 blocos em relação ao resultado obtido utilizando o intervalo de incerteza 1.

O recurso mineral inferido apresenta as maiores variações quando classificados pelos diferentes intervalos de incerteza propostos. Quando utilizado o intervalo de incerteza entre 35% e 100% diminui-se em 37% o volume de recurso inferido em relação a classificação que utiliza o intervalo de incerteza 1. Para os intervalos de incerteza 3 são classificados 4.437 blocos como recurso mineral inferido, o que representa um volume 66% menor do que o classificado pelos intervalos de incerteza 1.

A classe de Recurso Mineral Medido apresenta mudanças de volume significativas em relação aos diferentes intervalos de incerteza testados e isso pode ser explicado pela análise da distribuição das incertezas apresentada na Figura 43, onde se observa que os limites de incerteza utilizados para definir esta classe de recursos minerais encontram-se em meio às classes do histograma com maiores frequências, de modo que uma variação positiva de 5 pontos percentuais permite que uma nova classe do histograma que contém aproximadamente 6.000 blocos seja adicionada ao recurso mineral medido. De modo similar, isso também ocorre quando a variação é de 10 pontos percentuais, ou seja, são adicionados 11.259 blocos ao montante calculado com o limite em 15%.

Para a classe de recurso mineral indicado, a variação no número de blocos classificados é menor após o aumento dos limites de incerteza que a definem de 15% a 30% para 20% a 35% (intervalos de incerteza 2), ou até mesmo para 25 a 40% (intervalos de incerteza 3). Isso acontece porque o número de blocos classificados de acordo com esta classe praticamente se mantém mesmo com as variações nos intervalos de incerteza (Figura 44), sendo um pouco mais alteradas quando realizada a classificação pelos intervalos de incerteza 3 e comparada a classificação feita pelos intervalos de incerteza 2.

A classe de recurso mineral inferido é a mais sensível a variação dos intervalos de incerteza utilizados na sua definição e isso se deve à diminuição de aproximadamente 1 classe do histograma (Figura 45) a cada variação nos intervalos de incerteza, o que provoca a redução do número de blocos, e consequentemente de volume.

Em relação ao teor médio as variações são aceitáveis para todos os intervalos de incerteza propostos, pois para as classes de recurso mineral medido e indicado, mesmo considerando a incerteza máxima definida para cada intervalo de classe,

apenas a classe de recurso mineral indicado nos intervalos de incerteza 3 tem possibilidade de apresentar teor médio abaixo do teor de corte.

As variações em volume das classes de recursos minerais ocorridas quando são escolhidos diferentes intervalos de incertezas caracterizam um ponto importante a ser considerado na aplicação de métodos de classificação de recursos minerais baseados em intervalos de incerteza, sobretudo em depósitos minerais e corpos mineralizados onde os dados apresentam distribuição lognormal, caracterizada pela alta variabilidade de teores do minério, como notado no corpo de minério Sequeirinho.

Figura 43: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral medido (frequência expressa em número de blocos).

Fonte: Autor

Figura 44: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral indicado (frequência expressa em número de blocos).

Fonte: Autor

Figura 45: Distribuição de incertezas calculadas com 90% de confiança e limites dos intervalos de incerteza 1, 2 e 3 para a classificação de recurso mineral inferido (frequência expressa em número de blocos).

Fonte: Autor

Outra característica que permite identificar depósitos de alta variabilidade em teor é o Coeficiente de Variação (CV) (item 3.1.2). O Depósito estudado neste trabalho apresenta um Coeficiente de variação de 1,94, e isso reflete uma alta variabilidade de

teores que, de acordo com a Tabela 27 (Anexo A) retirada de Koch e Link (1971), é coerente com as observações advindas de depósitos de cobre e metais raros.

Na Figura 46 foi plotada a relação entre a média e o CV do corpo de minério Sequeirinho, juntamente com as observações apresentadas por Koch e Link (1971), e pode-se observar a alta variabilidade do alvo deste estudo, localizado entre as observações que apresentam maiores razões entre o coeficiente de variação e a média.

Figura 46: Coeficientes de Variação da Tabela 45.

Fonte: Modificado de Koch & Link (1971)

A partir da análise das distribuições de incerteza apresentadas neste item e das variações de volume observadas com a modificação dos intervalos de incerteza propostos pode-se afirmar que a escolha dos intervalos de incerteza mais adequados para a classificação de recursos minerais relaciona-se a variabilidade dos depósitos minerais, desse modo deve-se trata-los de forma diferente para cada caso, a depender do tipo de distribuição que o depósito avaliado e classificado apresenta. Assim os intervalos de incerteza devem ser escolhidos de modo a considerar a variabilidade intrínseca ao depósito mineral avaliado e, com isso, definir as classes de recursos minerais inequivocamente.

A susceptibilidade a pequenas variações dos intervalos de incerteza apontados por Rossi e Deutsch (2014) como sendo comumente utilizados para a classificação de recursos minerais quando aplicados métodos que fazem uso do intervalo de

confiança da média e de simulação condicional, mostra que há a necessidade de entender melhor as estatísticas dos depósitos, assim como a continuidade da mineralização, antes de serem definidos os parâmetros de incerteza que irão caracterizar cada classe de recurso.

Para o corpo de minério estudado neste trabalho e para outros depósitos que apresentam distribuição lognormal, o intervalo inicialmente utilizado para classificar o Recurso mineral como medido (incertezas até 15%) pode ser muito restritivo pois, de acordo com a distribuição de incertezas apresentada, os limites que definem recurso mineral medido e indicado estão localizados entre as classes que ocorrem com maior frequência.

5.9 Comparação com o método tradicional

Para efeito de comparação e para avaliar as variações dos intervalos de incerteza discutidos neste trabalho, optou-se por realizar a classificação de recursos minerais também por um método tradicionalmente utilizado pela indústria mineral que utiliza a vizinhança de krigagem para a definição das classes de recursos minerais. Por este método, de acordo com Dohm (2005) os parâmetros de classificação utilizados são:

- **Recurso Mineral Medido:** recursos estimados com vizinhança de krigagem ajustada para $2/3$ da variância espacial do modelo do variograma das amostras;
- **Recurso Mineral Indicado:** recursos minerais estimados com vizinhança de krigagem ajustada entre $2/3$ da variância espacial e variância espacial máxima do modelo de variograma das amostras.
- **Recurso Mineral Inferido:** recursos atravessados por furos de sonda localizados fora do raio de influência do variograma.

Como resultado da classificação obteve-se 40.086 blocos, sendo 30.716 classificados com recurso mineral medido e 9.370 classificados como recurso mineral indicado (Figuras 47 e 48). Não houve blocos classificados como recurso mineral inferido devido a utilização das mesmas vizinhanças de krigagem tanto para krigagem ordinária como para a definição da classe de recursos indicados.

Nota-se que pelo método de restrição de vizinhança de krigagem atinge-se um número maior de blocos medidos, o que pode conferir maior confiabilidade no empreendimento mineiro do ponto de vista do investidor, porém este método não considera a incerteza local associada aos blocos classificados como recurso mineral medido.

Quando considerada para categorizar blocos de minério em diferentes classes de recursos, a incerteza local pode contribuir significativamente para a geração de um número não esperado de recursos minerais inferidos em relação a outros métodos. Isso *a priori* não é interessante do ponto de vista econômico, pois pode parecer que o empreendimento apresenta potencial de lucro menor (considerando apenas a classificação de recursos). Porém, o conhecimento mais detalhado das regiões de alta incerteza permite que todas as etapas seguintes do projeto mineral avancem com maior cautela e integração para que, desta forma, seja possível alcançar bons resultados nas fases de reconciliação.

A diferença entre estes dois métodos de classificação está claramente relacionada a variabilidade local dos teores do minério. O método baseado na restrição da vizinhança de krigagem apresenta uma grande dependência da proximidade de amostras para que um dado bloco seja classificado como medido. A adição de amostras em regiões pouco amostradas aumenta significativamente o volume de recurso medido sem considerar a incerteza associada à sua localização, desta forma a conversão de recursos de uma classe para outra pode ser feita apenas em função de novas campanhas de amostragem.

Figura 47: Classificação de Recursos Minerais por restrição da vizinhança de krigagem.

Fonte: Autor

Figura 48: Resultado da classificação de recursos minerais por meio do método de restrição da vizinhança de krigagem.

Fonte: Autor

Outro problema do método que utiliza vizinhança de krigagem, abordado por Emery, Ortiz e Rodríguez (2006), é que a quantidade de blocos estimados como medidos pode ser imprecisa e condicionalmente enviesada se for calculada por uma vizinhança muito restrita. De acordo com Dohm (2005) este método é muito sensível ao efeito pepita, pois para depósitos onde este é muito alto e o campo estruturado do variograma é relativamente curto, como pode ser visto em depósitos de ouro como Witwatersrand (África do Sul), a maior parte dos blocos pode ser classificada como recurso mineral inferido. Ainda, Snowden (2001) salienta que classificações baseadas na distância média entre as amostras são melhores quando aplicadas a depósitos isotrópicos, pois no caso de anisotropia, somente a distância entre amostras não reflete adequadamente as relações espaciais.

O método baseado na incerteza utilizado neste trabalho utiliza a simulação condicional, que leva em consideração a variabilidade local dos dados e tem como vantagem a incorporação da incerteza para a definição das classes de recursos mineral.

Em relação a variação dos intervalos de incertezas propostos no item 5.9, quando os resultados do método tradicional (vizinhança de krigagem) são comparados aos resultados obtidos pelas classificações baseadas nos diferentes

intervalos de incerteza, nota-se que a classificação por meio dos intervalos de incerteza 3 é a que mais se assemelha, pois apresenta volume maior de recurso mineral medido e menor de recurso mineral inferido, porém ainda assim a diferença volumétrica para cada classe ainda é elevada.

Outra diferença é a homogeneidade em relação a distribuição espacial dos volumes ocupados tanto pela classe de Recurso Mineral Medido como de Recursos Mineral Inferido. No modelo classificado pelo método de Vizinhaça de Krigagem as classes de recursos são distribuídas espacialmente de forma mais homogênea e no modelo classificado por intervalo de incertezas ocorrem os indesejados “*spotted dogs*” (Stephenson et al., 2014), ou seja, há grande intercalação entre as classes classificadas e isso é mais evidente para as classificações segundo os intervalos de incerteza 1 e 2. A presença de “*spotted dogs*” reflete a variabilidade do teor do corpo mineralizado e por isso é mais recorrente em modelos classificados por métodos que levam em conta a incerteza local.

Dimitrakopoulos, Godoy e Chou (2009) chamam a atenção para um problema presente em métodos de classificação baseados no tamanho da malha de amostragem (distância entre as amostras). A Figura 49 mostra dois blocos com a mesma configuração de amostras a serem utilizadas na estimativa e, apesar do bloco 1 estar localizado em meio a amostras com valores mais próximos, ou seja, apresentar uma vizinhaça de baixa variabilidade e o bloco 2 ter as mesmas distâncias de amostras com valores que variam mais (vizinhaça de alta variabilidade), pelo método de classificação baseado na distância das amostras os dois blocos seriam categorizados na mesma classe.

Figura 49: Estimativa de bloco utilizando amostras com mesma configuração espacial e diferentes variabilidades locais de teores.

Fonte: Modificado de Dimitrakopoulos, Godoy e Chou (2009).

Este tipo de problema também pode ser observado comparando as classificações realizadas neste trabalho, onde verificou-se que 2.720 blocos

classificados como recurso mineral inferido nos modelos de classificação (pelos intervalos de incerteza 3) baseados na incerteza foram classificados como recurso mineral indicado quando o parâmetro de classificação utilizado foi a distância entre amostras. A Figura 50 mostra os blocos com incerteza maior do que 40% e que foram classificados com medidos pelo método que utiliza a distância entre amostras.

Figura 50: Blocos classificados com medidos pelo método de restrição da vizinhança de krigagem que apresentam incerteza maior que 40%.

Fonte: Autor

A partir dos questionamentos levantados sobre o método de classificação tradicionalmente utilizado como comparação ao método de classificação tema deste trabalho ficam evidentes as vantagens deste último, porém ainda assim é necessária a experiência do profissional encarregado pela avaliação de recursos minerais para a escolha dos intervalos de incerteza que melhor se ajustam ao tipo de depósito.

Apesar de não haver um método que define um intervalo de incerteza ótimo para categorizar cada classe de recursos minerais de forma precisa, o estudo apresentado neste trabalho mostra que para escolher este intervalo é necessário considerar o tipo de distribuição apresentada pelo depósito ou corpo mineralizado a ser avaliado.

6. Considerações Finais

A classificação de recursos minerais de acordo com os intervalos de incerteza calculados a partir dos resultados da simulação condicional discutidos por Rossi e Deutsch (2014) foi eficaz para os dados do corpo de minério Sequeirinho. Por esse método 40.087 blocos mineralizados foram classificados, onde 10.079 foram categorizados como recursos medidos, 16.881 como recursos indicados e 13.126 como recursos inferidos. A quantificação de metal contido dos recursos minerais resultou em 74,2 milhões de toneladas de recurso mineral medido a um teor médio de 1,62% de cobre, 51,2 milhões de toneladas de recurso mineral indicado a um teor médio de 0,67% de cobre e 24,6 milhões de toneladas de recurso mineral inferido a um teor médio de 0,41% de cobre.

O método de classificação de recursos minerais utilizado neste trabalho leva em consideração a variabilidade local dos dados e apresenta como vantagem a incorporação da incerteza para a definição das classes de recursos minerais.

A simulação condicional representa a incerteza associada a cada local no modelo e caracteriza-se como ótima ferramenta a ser utilizada para tomadas de decisão. O intervalo de confiança e a incerteza calculada, quando utilizados para a determinação de classes de recursos minerais, apresenta juntamente com as simulações o nível de confiança estabelecido para o cálculo (nesse trabalho de 90%) e pode refletir o grau de risco de forma objetiva, atendendo com eficácia as exigências estabelecidas pelos padrões internacionais de declaração de recursos e reservas minerais.

Neste trabalho ficou evidente a sensibilidade a pequenas variações dos intervalos de incerteza utilizados para a definição das classes de recursos minerais e ficou claro que o tipo de distribuição de frequência dos dados amostrais tem um papel importante na escolha desses intervalos. Desta forma entende-se que depósitos que apresentam alta variabilidade devem ser tratados de forma diferente dos depósitos de baixa variabilidade quando se trata da escolha de intervalos de incerteza.

O intervalo de 0 a 15% de incerteza para classificar o recurso mineral como medido pode ser muito restritivo para depósitos que apresentam distribuição lognormal, sendo que um intervalo mais abrangente resultará em uma quantidade de recursos medidos significativamente maior visto que as classes do histograma de

incertezas que contém o limite entre recurso mineral medido e indicado são as que ocorrem em maior frequência, porém a variação e a escolha deste intervalo não segue um padrão e continua a depender da experiência do profissional responsável pela avaliação de recursos minerais.

Apesar de ser um método consolidado para quantificar a incerteza, a simulação condicional ainda é pouco utilizada na indústria para fins de classificação de recursos minerais e alguns fatores que contribuem para isso são: a falta de conhecimento sobre o método na indústria mineral, a presença de “spotted dogs” nos modelos de recursos minerais e a maior quantidade de recursos minerais em classes de menor confiabilidade (indicados e inferidos) contribuem para que métodos tradicionais sejam considerados mais adequados na prática e, por isso, sejam mais difundidos na indústria mineral.

Acredita-se haver uma tendência crescente na utilização de simulação condicional pela indústria mineira, como já aventada por Goovaerts (1997). Tanto com a finalidade de classificar recursos minerais quando para avaliação de risco em diferentes fases do empreendimento mineiro, é notado um aumento no interesse internacional por tal técnica (Rossi e Deutsch, 2014), apesar de ainda haver a predominância no uso de métodos que não consideram a incerteza para a classificação de recursos e reservas. Espera-se que nas próximas décadas esse método faça parte da rotina de estimativa e avaliação de recursos e reservas minerais também nas empresas mineradoras do Brasil.

Por fim, são elencados os benefícios da utilização de simulação condicional e intervalo de confiança da média para quantificar a incerteza:

- Pode evitar a execução de campanhas de sondagem desnecessárias
- Contribui para a identificação de regiões com maior necessidade de pesquisa com o objetivo de minimizar a incerteza;
- Obtém um espectro de possíveis cenários aliado às classes de recursos minerais;
- Reflete tanto a incerteza presente no modelo geológico como no modelo de previsão e, por isso, denota grau de confiança mais robusto para a definição de classes de recursos minerais segundo padrões internacionalmente aceitos.

7. Referências Bibliográficas

ABZALOV, M. **Applied mining geology**. Berlin: Springer, 2016.

ARMSTRONG, M. **Basic linear geostatistics**. Berlin: Springer, 1998.

AUGUSTO, R. A. et al. Zonas de alteração hidrotermal e paragênese do minério de cobre do Alvo Bacaba, Província Mineral de Carajás (PA). **Revista Brasileira de Geociências**, v. 38, n. 2, p. 263-277, 2008.

AusIMM. **Australasian Code for Reporting of Mineral Resources and Ore Reserves (The JORC Code)**. Joint Ore Reserves Committee of The Australasian Institute of Mining and Metallurgy, Australian Institute of Geoscientists and Minerals Council of Australia. 1999. Disponível em <<http://www.jorc.com>>. Acesso em: 11 nov. 2017.

BÁRDOSSY, G.; FODOR, J. **Evaluation of uncertainties and risks in geology: new mathematical approaches for their handling**. New York: Springer, 2004.

BLACKWELL, G. Relative kriging errors; a basis for mineral resource classification. **Exploration and Mining Geology**, v. 7, n. 1-2, p. 99-105, 1998.

BORRADAILE, G. J. **Statistics of Earth Science data: their distribution in time, space and orientation**. New York: Springer, 2003.

CAERS, J. **Modeling uncertainty in the Earth Sciences**. Wiley-Blackwell, 2011.

CIM. **National Instrument 43-101 Standards of Disclosure for Mineral Projects. Canadian Securities Administrators (CSA)**. 2011. Disponível em <<http://web.cim.org/standards/menupage.cfm?sections=177,181&menu=229>> Acessado em: 11 nov. 2017.

CRIRSCO. **International Reporting Template for the Public Reporting of exploration Results, Mineral Resources and Mineral Reserves**. The Committee for Mineral Reserves International Reporting Standards. 2013. Disponível em: <http://www.criusco.com/crisco_template_v2.pdf> Acesso em: 22 jul 2017.

CBRR. **Guia CBRR Para Declaração de Resultados de Exploração, Recursos e Reservas Minerais. Comissão Brasileira de Recursos e Reservas**. 2016. Disponível em <<http://www.cbrr.org.br/docs/estatuto.pdf>> Acesso em: 25 jan. 2018.

CHILÈS J.P.; DELFINER P. **Geostatistics**: Modeling Spatial Uncertainty. Agawan: Willey & Sons, 1999.

CORTES, A.. Comparison of Two Multivariate Grade Simulation Approaches on an Iron Oxide Copper-Gold Deposit. In: **Geostatistics Valencia 2016**. Springer, Cham, 2017. p. 151-166.

DAVIS, J.C. **Statistics and data analysis in geology**. New York: Willey & Sons, 2002.

DEUTSCH, C. V.; JOURNEL, A. G. **Geostatistical software library and user's guide**. New York: Oxford University Press, 1998.

DEUTSCH, C. V. **Geostatistical Reservoir Modeling**. New York: Oxford University Press, 2002.

DIMITRAKOPOULOS, R. Conditional simulation algorithms for modelling orebody uncertainty in open pit optimisation. **International Journal of Surface Mining, Reclamation and Environment**, v. 12, n. 4, p. 173-179, 1998.

DIMITRAKOPOULOS, R.; GODOY, M.; CHOU, C. L. Resource/reserve classification with integrated geometric and local grade variability measures. In: **proceedings, Orebody modelling and strategic mine planning**. 2009. p. 207-214.

DOHM, C. Quantifiable mineral resource classification: A logical approach. In: **Geostatistics Banff 2004**. Dordrecht: Springer, p. 333-342, 2005.

DOMINY, S.C.; NOPPÉ, M. A.; ANNELS, A. E. Errors and uncertainty in mineral resource and ore reserve estimation: The importance of getting it right. **Exploration and Mining Geology**, v. 11, n. 1-4, p. 77-98, 2002.

DUKE, J. H.; HANNA, P. J. Geological interpretation for resource modelling and estimation. **Mineral Resource and Ore Reserve Estimation—The AusIMM Guide to Good Practice**, second edition (Monograph 30), p. 145-153, 2014.

EMERY, Xavier; ORTIZ, Julián M.; RODRÍGUEZ, Juan J. Quantifying uncertainty in mineral resources by use of classification schemes and conditional simulations. **Mathematical Geology**, v. 38, n. 4, p. 445-464, 2006.

EVERITT, B. S.; SKRONDAL, A. **The Cambridge dictionary of statistics.**

Cambridge: Cambridge University Press, 2002.

FREITAS, S. B. M. **Planejamento estocástico de lavra:** metodologias de simulação, otimização e gestão de risco para a mina do futuro. 2015. 179 p. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e Petróleo, São Paulo, 2015.

FROIDEVAUX, R.; ROSCOE, W. E.; VALIANT, R. I. Estimating and classifying gold reserves at Page-Williams C zone: a case study in nonparametric geostatistics. In: **Proceedings of the Symposium on Ore reserve estimation Methods, models and reality: Canadian Institute of Mining, Metallurgy and Petroleum, Montreal.** 1986. p. 280-300.

GOLDER ASSOCIATES. Vale S.A. External Audit Of Mineral Reserves Volume 2, Section 8. Sossego Mine. 2010 Disponível em: https://www.miningdataonline.com/reports/Sossego_06302010_TR.pdf

GOOVAERTS, P. 1997. **Geostatistics for Natural Resources Evaluation.** New York: Oxford University Press.

HENLEY, S.; ALLINGTON, R. PERC, CRIRSCO, and UNFC: minerals reporting standards and classifications. **European Geologist European Geologist**, p. 49, 2013.

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

JOINT COMITEE FOR GUIDES IN METROLOGY (JCGM). **Evaluation of measurement data —Guide to the expression of uncertainty in measurement (GUM).** 2008. <<https://www.iso.org/sites/JCGM/GUM/JCGM100/C045315e.html/C045315e.html?csnumber=50461>>. Acesso em: 23 jul 2017.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining geostatistics.** London: Academic Press, 1978.

JOURNEL, A. G. Nonparametric estimation of spatial distributions. **Journal of the International Association for Mathematical Geology**, v. 15, n. 3, p. 445-468, 1983.

JOURNEL, A. G.; JOURNEL, André G. **Fundamentals of geostatistics in five lessons**. Washington, DC: American Geophysical Union, 1989.

KOCH, G.S.; LINK, R. F. The coefficient of variation; a guide to the sampling of ore deposits. **Economic Geology**, v. 66, n. 2, p. 293-301, 1971.

LANDIM, P. M. B. Sobre geoestatística e mapas. **Terrae Didactica**, v. 2, n. 1, p. 19-33, 2006.

LANTUÉJOUL, C.. **Geostatistical simulation: models and algorithms**. New York: Springer, 2002.

LEUANGTHONG, O.; MCLENNAN, J. A.; DEUTSCH, C. V. Minimum acceptance criteria for geostatistical realizations. **Natural Resources Research**, v. 13, n. 3, p. 131-141, 2004.

MAGALHÃES, M. N.; DE LIMA, A. C. P.. **Noções de probabilidade e estatística**. São Paulo: Editora da Universidade de São Paulo, 2002.

MANN, C. J. 1993. Uncertainty in Geology. In: **DAVIS, J. C. & HERZFELD, U. C. 1993 Computers in Geology – 25 Years of Progress**. New York: Oxford University Press. 241-254 p.

MATHERON, G. 1965. **Les variables régionalisées et leur estimation**. Paris: Masson, 1965.

MISKELLY, N. Progress on international standards for reporting of mineral resources and reserves. In: **Conference on resource reporting standards, Reston**. 2003.

MONTEIRO, L.V.S. et al. 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. **Mineralium Deposita**, v. 43, n. 2, p. 129-159, 2008a.

MONTEIRO, L.V.S. et al. Metalogênese da Província Carajás. **Metalogênese Das Províncias Tectônicas Brasileiras**, p. 43, 2014.

Neves M.P. **Estudos isotópicos (Pb-Pb, Sm-Nd, C e O) do depósito Cu-Au do Sossego, Província Mineral de Carajás**. 2006.104p.Dissertação de Mestrado (Geologia) – Centro de geociências, Universidade federal do Pará, Belém, 2006.

PERC. **Pan-European Standard for Reporting of Exploration Results, Mineral Resources and Reserves (The PERC Reporting Standard)**. The Pan-European Reserves and Resources Reporting Committee. 2013. Disponível em: <<http://www.percstandard.eu/>> Acesso em: 12 nov. 2017.

R CORE TEAM. **R: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing; 2017. Disponível em: <http://www.R-project.org/>

REVUELTA, M. B. **Mineral Resources: From Exploration to Sustainability Assessment**. Springer, 2017.

RIVOIRARD, J. **Introduction to disjunctive kriging and non-linear geostatistics**. New York: Oxford University Press, 1994.

ROSSI, M. E. DEUTSCH, C. V.; **Mineral Resource Estimation**. New York: Springer, 2014.

ROYLE, A. G. How to use geostatistics for ore reserve classification. **World Mining**, v. 30, p. 52-56, 1977.

SABOURIN, R. L. Application of a geostatistical method to quantitatively define various categories of resources. In: **Geostatistics for natural resources characterization**. Dordrecht: Springer, 1984. p. 201-215.

SAMREC. **South African Code for the Reporting of Exploration Results, Mineral Resources and Mineral Reserves (The SAMREC Code)**. The South African Mineral Resource Committee and South African Institute of Mining and Metallurgy. 2016. Disponível em: <<http://www.samcode.co.za/>>. Acesso em: 12 nov. 2016.

SOARES, A. **Geoestatística para as Ciências da Terra e do Ambiente**. 2ª Edição. Coleção Ensino da Ciência e Tecnologia. Instituto Superior Técnico, 2006.

SILVA, D. S. F.; BOISVERT, J. B. Mineral resource classification: a comparison of new and existing techniques. **Journal of the Southern African Institute of Mining and Metallurgy**, v. 114, n. 3, p. 265–273, 2014.

SIMON, J. Three Australian Asset-Price Bubbles. In: **Asset Prices and Monetary Policy, Proceedings of a Conference**. Economic Group Reserve Bank of Australia. Sydney: J.S. McMillan Printing Group, pp 8–41, 2003.

SME. **SME Guide for Reporting Exploration Results, Mineral Resources, and Mineral Reserves**. The Society for Mining, Mineral Resources, and Exploration.

2017. Disponível em https://www.smenet.org/SME/media/Publications-Resources/SMEGuideReporting_082017.pdf. Acesso em 23 jul. 2018.

STEPHENSON, P. R. et al. Mineral Resource Classification—It's Time to Shoot The "Spotted Dog"! In: **Proceedings Sixth International Mining Geology Conference**. 2006. p. 91-96.

SNOWDEN, D. V. Practical interpretation of mineral resource and ore reserve classification guidelines. **Mineral Resource and Ore Reserve Estimation—The AusIMM Guide to Good Practice**. Australasian Institute of Mining and Metallurgy, Monograph, v. 23, p. 653-660, 2001.

SPIEGEL, M. R. **Estatística**. São Paulo: McGraw Hill, 1967.

WELLMER, F.W. **Statistical Evaluations in Exploration for Mineral deposits**. Berlin: Springer, 379p, 1998.

YAMAMOTO, J. K. An alternative measure of the reliability of ordinary kriging estimates. **Mathematical Geology**, v. 32, n. 4, p. 489-509, 2000.

YAMAMOTO, J. K. 2001. Análise Geoestatística. In: **YAMAMOTO, J. K., 2001, Avaliação e Classificação de Reservas Minerais**. Editora da Universidade de São Paulo, São Paulo, p. 72-78.

YAMAMOTO, J. K. BETTENCOURT, J. S. MONTANHEIRO, T. S. 2001. Análise Estatística. In: **YAMAMOTO, J. K. 2001. Avaliação e Classificação de Reservas Minerais**. Editora da Universidade de São Paulo, São Paulo, 225 p.

YAMAMOTO, J.K.; CHAO, L. Comparação de métodos para teste de bigaussianidade. **Geociências**, v. 28, n. 2, p. 121-128, 2009.

YAMAMOTO J. K.; LANDIM P., M., B. **Geoestatística: Conceitos e Aplicações**. São Paulo: Oficina de Textos, 2013.

ZIMMERMANN, H.J. An application-oriented view of modeling uncertainty. **European Journal of operational research**, v. 122, n. 2, p. 190-198, 2000.

ANEXO A – Tabelas

Tabela 25: Estatísticas descritivas das realizações resultantes da simulação sequencial gaussiana no campo gaussiano.

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00001]	84464	-4,17	4,31	-0,02	0,99	0,98
[00002]	84464	-4,7	4,25	-0,02	0,99	0,97
[00003]	84464	-4,24	4,51	-0,02	0,99	0,98
[00004]	84464	-3,92	4,08	-0,03	0,98	0,97
[00005]	84464	-4,15	3,96	-0,03	0,98	0,96
[00006]	84464	-4,17	4,14	-0,04	0,98	0,97
[00007]	84464	-4,78	4,88	-0,04	0,99	0,98
[00008]	84464	-4,41	3,97	-0,02	0,99	0,98
[00009]	84464	-4,75	4,28	-0,03	0,99	0,98
[00010]	84464	-4,75	4,36	-0,02	0,99	0,98
[00011]	84464	-3,91	4,21	-0,02	0,99	0,98
[00012]	84464	-4,52	4,38	-0,03	0,99	0,97
[00013]	84464	-4,41	4,06	-0,03	0,98	0,97
[00014]	84464	-4,37	4,66	-0,02	0,98	0,97
[00015]	84464	-4	4,18	-0,03	0,99	0,97
[00016]	84464	-4,15	4,19	-0,03	0,98	0,97
[00017]	84464	-4,44	4,49	-0,03	0,99	0,98
[00018]	84464	-4,74	4,09	-0,02	0,98	0,97
[00019]	84464	-4,31	4,26	-0,02	0,99	0,97
[00020]	84464	-4,31	4,49	-0,02	0,99	0,98
[00021]	84464	-4,27	4,3	-0,02	0,99	0,98
[00022]	84464	-4,43	4,19	-0,03	0,98	0,97
[00023]	84464	-4,35	4,38	-0,02	0,99	0,97
[00024]	84464	-4,19	4,11	-0,03	0,98	0,97
[00025]	84464	-4,42	4,34	-0,03	0,99	0,98
[00026]	84464	-4,17	4,38	-0,02	0,99	0,98
[00027]	84464	-4,07	4,98	-0,02	0,98	0,96
[00028]	84464	-4,91	4,59	-0,01	0,99	0,98
[00029]	84464	-4,18	4,71	-0,03	0,98	0,97
[00030]	84464	-4,39	4,07	-0,03	0,99	0,98
[00031]	84464	-4,75	5,16	-0,02	0,98	0,97
[00032]	84464	-4,05	4,56	-0,02	0,98	0,97
[00033]	84464	-4,04	3,98	-0,03	0,99	0,98
[00034]	84464	-4,09	4,28	-0,02	0,99	0,98
[00035]	84464	-4,16	4,09	-0,03	0,98	0,96
[00036]	84464	-4,3	5,14	-0,01	0,98	0,97

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00037]	84464	-4,33	4,22	-0,02	0,98	0,97
[00038]	84464	-4,43	4,13	-0,02	0,99	0,97
[00039]	84464	-4,55	4,46	-0,02	0,98	0,97
[00040]	84464	-4,35	4,74	-0,02	0,99	0,98
[00041]	84464	-4,21	4,43	-0,02	0,99	0,98
[00042]	84464	-4,05	4,1	-0,02	0,99	0,98
[00043]	84464	-4,35	4,31	-0,02	0,99	0,98
[00044]	84464	-4,54	4,2	-0,02	0,99	0,97
[00045]	84464	-4,54	4,06	-0,02	0,99	0,98
[00046]	84464	-4,67	3,84	-0,02	0,99	0,98
[00047]	84464	-3,99	4,28	-0,02	0,98	0,97
[00048]	84464	-4,51	4,39	-0,02	0,98	0,97
[00049]	84464	-4,38	3,85	-0,02	0,98	0,97
[00050]	84464	-4,25	4,69	-0,02	0,99	0,98
[00051]	84464	-4,36	4,12	-0,03	0,98	0,97
[00052]	84464	-4,24	4,19	-0,01	0,99	0,98
[00053]	84464	-4,93	4,65	-0,03	0,99	0,97
[00054]	84464	-4,69	4,52	-0,02	0,99	0,98
[00055]	84464	-4,17	4,24	-0,02	0,99	0,97
[00056]	84464	-4,02	4,09	-0,03	0,99	0,98
[00057]	84464	-3,94	4,68	-0,02	0,99	0,98
[00058]	84464	-4,2	4,43	-0,02	0,98	0,97
[00059]	84464	-4,08	4,52	-0,02	0,98	0,97
[00060]	84464	-4,04	4,11	-0,02	0,99	0,97
[00061]	84464	-4,29	4,4	-0,02	0,99	0,98
[00062]	84464	-4,4	3,84	-0,03	0,98	0,97
[00063]	84464	-4,36	4,03	-0,02	0,99	0,98
[00064]	84464	-4,17	4,17	-0,03	0,99	0,98
[00065]	84464	-4,21	4,31	-0,02	0,99	0,97
[00066]	84464	-4,08	4,88	-0,02	0,99	0,98
[00067]	84464	-4,65	4,24	-0,01	0,98	0,96
[00068]	84464	-4,47	4,4	-0,02	0,99	0,98
[00069]	84464	-4,56	4,93	-0,03	0,99	0,98
[00070]	84464	-4,24	4,89	-0,02	0,98	0,97
[00071]	84464	-4,08	4,23	-0,03	0,99	0,97
[00072]	84464	-5,27	4,55	-0,03	0,98	0,97
[00073]	84464	-4,63	3,98	-0,02	0,99	0,97
[00074]	84464	-4,61	4,48	-0,03	0,99	0,98
[00075]	84464	-4,36	3,91	-0,02	0,98	0,97
[00076]	84464	-4,57	4,22	-0,02	0,99	0,98
[00077]	84464	-3,99	4,49	-0,02	0,99	0,98
[00078]	84464	-4,26	4,29	-0,01	0,99	0,98
[00079]	84464	-3,96	4,68	-0,03	0,99	0,98
[00080]	84464	-4	4,21	-0,02	0,99	0,98
[00081]	84464	-4,19	4,2	-0,02	0,99	0,97

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00082]	84464	-5,18	4,15	-0,01	0,99	0,98
[00083]	84464	-4,3	4,23	-0,04	0,99	0,97
[00084]	84464	-4,06	4,18	-0,02	0,98	0,96
[00085]	84464	-4,14	4,51	-0,02	0,99	0,98
[00086]	84464	-4,05	3,79	-0,02	0,99	0,97
[00087]	84464	-4,28	4,64	-0,02	0,98	0,97
[00088]	84464	-4,56	3,98	-0,02	0,98	0,97
[00089]	84464	-4,1	3,87	-0,01	0,99	0,98
[00090]	84464	-4,52	4,08	-0,03	0,98	0,96
[00091]	84464	-4,4	4,44	-0,02	0,99	0,98
[00092]	84464	-4,77	4,47	-0,03	0,98	0,97
[00093]	84464	-4,81	4,29	-0,04	0,98	0,96
[00094]	84464	-4,22	3,84	-0,03	0,98	0,97
[00095]	84464	-4,15	4,12	-0,03	0,99	0,97
[00096]	84464	-4,62	4,4	-0,02	0,99	0,98
[00097]	84464	-4,13	4,15	-0,03	0,98	0,97
[00098]	84464	-5,11	3,93	-0,01	0,99	0,98
[00099]	84464	-5,46	4,19	-0,02	0,99	0,97
[00100]	84464	-4,39	4,08	-0,03	0,98	0,97

Tabela 26: Estatísticas descritivas das realizações resultantes da simulação sequencial gaussiana após a transformação inversa.

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00001]	84464	0,01	39,08	0,52	1	1
[00002]	84464	0,01	39,08	0,52	0,97	0,94
[00003]	84464	0,01	39,08	0,52	1,02	1,03
[00004]	84464	0,01	39,08	0,5	0,94	0,89
[00005]	84464	0,01	39,08	0,51	0,94	0,88
[00006]	84464	0,01	39,08	0,5	0,97	0,94
[00007]	84464	0,01	39,08	0,5	0,95	0,91
[00008]	84464	0,01	39,08	0,52	0,97	0,93
[00009]	84464	0,01	39,08	0,51	0,97	0,93
[00010]	84464	0,01	39,08	0,51	0,96	0,93
[00011]	84464	0,01	39,08	0,52	0,99	0,99
[00012]	84464	0,01	39,08	0,51	0,96	0,93
[00013]	84464	0,01	39,08	0,51	0,97	0,95
[00014]	84464	0,01	39,08	0,51	0,97	0,94
[00015]	84464	0,01	39,08	0,51	0,99	0,99
[00016]	84464	0,01	39,08	0,51	0,95	0,9
[00017]	84464	0,01	39,08	0,51	1,01	1,01
[00018]	84464	0,01	39,08	0,51	0,97	0,94
[00019]	84464	0,01	39,08	0,52	1	0,99
[00020]	84464	0,01	39,08	0,52	0,96	0,93
[00021]	84464	0,01	39,08	0,52	0,98	0,97
[00022]	84464	0,01	39,08	0,51	0,99	0,98
[00023]	84464	0,01	39,08	0,52	1,01	1,02
[00024]	84464	0,01	39,08	0,5	0,94	0,88
[00025]	84464	0,01	39,08	0,51	0,96	0,93
[00026]	84464	0,01	39,08	0,51	0,96	0,92
[00027]	84464	0,01	39,08	0,51	0,98	0,96
[00028]	84464	0,01	39,08	0,52	1	0,99
[00029]	84464	0,01	39,08	0,51	0,98	0,96
[00030]	84464	0,01	39,08	0,51	0,97	0,94
[00031]	84464	0,01	39,08	0,51	1,01	1,01
[00032]	84464	0,01	39,08	0,51	0,99	0,98
[00033]	84464	0,01	39,08	0,51	0,97	0,94
[00034]	84464	0,01	39,08	0,52	0,97	0,95
[00035]	84464	0,01	39,08	0,51	0,94	0,88
[00036]	84464	0,01	39,08	0,52	0,94	0,88
[00037]	84464	0,01	39,08	0,51	0,96	0,93
[00038]	84464	0,01	39,08	0,51	0,98	0,97
[00039]	84464	0,01	39,08	0,52	1	1
[00040]	84464	0,01	39,08	0,52	1	1

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00041]	84464	0,01	39,08	0,52	1	0,99
[00042]	84464	0,01	39,08	0,52	1,03	1,06
[00043]	84464	0,01	39,08	0,52	0,97	0,93
[00044]	84464	0,01	39,08	0,51	0,95	0,9
[00045]	84464	0,01	39,08	0,52	0,99	0,99
[00046]	84464	0,01	29,17	0,52	0,97	0,93
[00047]	84464	0,01	39,08	0,51	1	1
[00048]	84464	0,01	39,08	0,51	0,95	0,91
[00049]	84464	0,01	29,62	0,51	0,92	0,85
[00050]	84464	0,01	39,08	0,52	1,03	1,06
[00051]	84464	0,01	39,08	0,5	0,95	0,9
[00052]	84464	0,01	39,08	0,52	1	0,99
[00053]	84464	0,01	39,08	0,51	0,94	0,89
[00054]	84464	0,01	39,08	0,51	0,97	0,94
[00055]	84464	0,01	39,08	0,52	1	0,99
[00056]	84464	0,01	39,08	0,51	0,95	0,91
[00057]	84464	0,01	39,08	0,52	0,99	0,98
[00058]	84464	0,01	39,08	0,52	0,99	0,98
[00059]	84464	0,01	39,08	0,52	1	1
[00060]	84464	0,01	39,08	0,51	0,98	0,96
[00061]	84464	0,01	39,08	0,52	1,01	1,03
[00062]	84464	0,01	29,18	0,5	0,93	0,87
[00063]	84464	0,01	39,08	0,52	1	0,99
[00064]	84464	0,01	39,08	0,51	0,97	0,95
[00065]	84464	0,01	39,08	0,51	0,99	0,97
[00066]	84464	0,01	39,08	0,52	0,98	0,96
[00067]	84464	0,01	39,08	0,52	0,99	0,97
[00068]	84464	0,01	39,08	0,51	1	0,99
[00069]	84464	0,01	39,08	0,51	1,02	1,03
[00070]	84464	0,01	39,08	0,51	0,97	0,93
[00071]	84464	0,01	39,08	0,51	0,98	0,96
[00072]	84464	0,01	39,08	0,5	0,97	0,95
[00073]	84464	0,01	39,08	0,51	0,98	0,96
[00074]	84464	0,01	39,08	0,51	0,97	0,93
[00075]	84464	0,01	31,49	0,51	0,93	0,87
[00076]	84464	0,01	39,08	0,51	0,96	0,93
[00077]	84464	0,01	39,08	0,52	1	1
[00078]	84464	0,01	39,08	0,52	1	1,01
[00079]	84464	0,01	39,08	0,51	0,95	0,9
[00080]	84464	0,01	39,08	0,52	0,97	0,94
[00081]	84464	0,01	39,08	0,51	0,97	0,94
[00082]	84464	0,01	39,08	0,52	0,98	0,96
[00083]	84464	0,01	39,08	0,5	0,94	0,89
[00084]	84464	0,01	39,08	0,51	0,96	0,92

Realizações	Blocos	Mínimo	Máximo	Média	Desvio Padrão	Variância
[00085]	84464	0,01	39,08	0,52	1,01	1,02
[00086]	84464	0,01	27,45	0,51	0,94	0,88
[00087]	84464	0,01	39,08	0,52	1	0,99
[00088]	84464	0,01	39,08	0,51	0,95	0,9
[00089]	84464	0,01	30,07	0,52	0,95	0,91
[00090]	84464	0,01	39,08	0,5	0,93	0,86
[00091]	84464	0,01	39,08	0,52	0,99	0,99
[00092]	84464	0,01	39,08	0,51	0,98	0,96
[00093]	84464	0,01	39,08	0,5	0,93	0,87
[00094]	84464	0,01	29,35	0,51	0,96	0,93
[00095]	84464	0,01	39,08	0,51	0,98	0,96
[00096]	84464	0,01	39,08	0,51	0,96	0,92
[00097]	84464	0,01	39,08	0,51	0,98	0,95
[00098]	84464	0,01	32,16	0,52	0,96	0,93
[00099]	84464	0,01	39,08	0,52	0,99	0,98
[00100]	84464	0,01	39,08	0,5	0,93	0,86

Tabela 27: Estatísticas de 50.057 observações de 484 depósitos minerais.

Substância	Fórmula Química	Média	Variância	Coefficiente de Variação	Número de depósitos	Número de observações
Prata	Ag	0,0200	0,000595	1.218	18	971
Alumínio	Al ₂ O ₃	29,4	41,16	0.218	39	8888
Carbonato	CaO	14,33	91,83	0.669	7	1099
Calcita	CaCO ₃	5,28	39,14	1.185	24	1059
Cromita	Cr ₂ O ₃	15,92	90,66	0.598	40	3592
Cobre	Cu	1,66	7,33	1.631	16	843
Magnetita	Fe	26,81	80,58	0.335	30	2810
Ferro	Fe ₂ O ₃	37,44	105,56	0.274	14	1449
Magnésio	MgO	25,2	146,41	0.480	2	347
Manganês	Mn	14,25	67,63	0.577	63	7711
Níquel	Ni	1,02	4,12	1.990	24	2091
Fósforo	P	0,277	0,0668	0.934	18	1307
Fosfato	P ₂ O ₅	17,6	83,68	0.520	32	1569
Chumbo	Pb	2,81	16,05	1.426	8	342
Enxofre	S	4,32	43,84	1.533	5	494
Sílica	SiO ₂	33,89	143,35	0.353	42	6044
Titânio	TiO ₂	14,72	14,74	0.261	4	621
Urânio	U ₃ O ₈	0,402	0,299	1.360	3	519
Vanádio	VaO ₅	1,27	3,36	1.443	25	1286
Tungstênio	WaO ₃	0,587	1,685	2.211	34	4019
Zinco	Zn	4,47	28,17	1.187	36	2976

Fonte: Koch e Link (1971)

ANEXO B – Figuras

Figura 51: Mapa base da localização das sondagens de diferentes campanhas que deram origem a base de dados utilizada neste trabalho.

Fonte: Autor