

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MINAS, METALÚRGICA
E DE MATERIAIS (PPGE3M)

**ESTUDO DE MALHA ÓTIMA E CORRELAÇÃO DO MÁXIMO ERRO DA
ESTIMATIVA (MEE) ENTRE VOLUMES DE PRODUÇÃO DE LONGO E CURTO
PRAZO**

Aline Maria de Rezende Amaral

Porto Alegre

2022

ALINE MARIA DE REZENDE AMARAL

Dissertação submetida ao Programa de Pós-graduação em Engenharia de Minas, Metalúrgica e de Materiais PPGE3M da Universidade Federal do Rio Grande do Sul, como requisito parcial à obtenção do título de Mestre em Engenharia.

Orientador: Prof. João Felipe Coimbra Leite Costa

Co-orientador: Prof. Diego Machado Marques

Porto Alegre

2022

À minha família: Mário (Pai), Cristina (Mãe), Camilla (irmã) e Igo (Marido), por serem minha base e pelo apoio incondicional. Amo vocês.

AGRADECIMENTO

Agradeço à Universidade Federal do Rio Grande do Sul (UFRGS) e ao PPGE3M pelo ensino de qualidade. Ao professor João Felipe pelos ensinamentos, orientação, recepção e oportunidade de fazer parte do LPM. Ao Diego Marques, pelas ideias, orientação e amizade. À professora Vanessa Koppe, pelo auxílio constante no desenvolvimento desse trabalho, incentivo, paciência e transmissão de conhecimento, muito obrigada! Aos colegas geostatísticos, especialmente David e Augustinho, pelas trocas de conhecimento e amizade e a todos os amigos do LPM que contribuiriam de alguma forma para finalização desse trabalho.

Agradeço imensamente à empresa Lundin Mining, pela qual guardo imenso carinho, pelo apoio e interesse neste trabalho e por permitirem que ele se concretizasse, Raquel pelo incentivo. À AngloGold Ashanti, minha casa atual, pelos ensinamentos. Aos colegas da Geovariances (especialmente Silvia), da Datamine e da Seequent, sempre presentes.

Aos meus pais, pelo apoio constante, meu amor, Igo, pelo incentivo diário, meus amigos de Goiás, Belo Horizonte, Ouro Preto e Rio Grande do Sul, pelos momentos de apoio e descontração.

RESUMO

Erros associados à estimativa de um atributo de interesse de um depósito, por exemplo o teor de um elemento, podem comprometer decisões de planejamento, sequenciamento e de beneficiamento mineral dentro de uma empresa. Vários fatores estão associados aos erros de estimativa, entre eles podemos destacar aspectos associados ao espaçamento amostral, ao tamanho dos volumes de produção e à variabilidade do atributo considerado na estimativa. Em geral, temos que, à medida que o espaçamento entre as amostras diminui e/ou o volume de produção aumenta, o erro da estimativa tende a diminuir e, à medida que o coeficiente de variação do atributo de interesse aumenta, o erro tende a aumentar. Para redução do espaçamento amostral, mais investimentos financeiros precisam ser feitos em sondagem, portanto, deve-se analisar sempre o ótimo espaçamento que vai proporcionar um erro de estimativa aceitável e que esteja dentro do orçamento da empresa destinado à perfuração.

A previsão da incerteza relacionada à estimativa pode ser feita por alguns métodos geoestatísticos, por exemplo, por simulação estocástica, porém esse é um processo que exige conhecimento da técnica e demanda tempo. Trabalhos anteriores propuseram um método simplificado e de fácil consulta para o acesso ao Máximo Erro da Estimativa (MEE) associado a diferentes tipos de variáveis de teor, em função do espaçamento amostral, dentro de volumes de produção pequenos, de curto prazo e faixas de coeficiente de variação específicas. Essa dissertação estudará as correlações dos resultados de MEE já obtidos na literatura para volumes de curto prazo com resultados de MEE obtido para volumes de longo prazo, analisados neste trabalho, visando permitir um rápido acesso ao MEE para volumes maiores também.

Este trabalho trará importantes considerações sobre o MEE obtido por simulação geoestatística para diferentes padrões de amostragem e volumes de produção do depósito de Chapada, do tipo Cu-Au, localizado no interior do estado de Goiás. Atualmente, a utilização do MEE também para a classificação de recursos, dentro de volumes de produção definidos, vem crescendo na indústria, seguindo a proposta de estudos anteriores. Dessa forma, nesta dissertação, correlações serão mostradas entre volumes menores, de curto prazo, e volumes de produção maiores e serão feitas considerações sobre essas análises sob a ótica da classificação de recursos.

ABSTRACT

Errors associated with estimating the grade of an attribute of interest in a deposit can compromise planning, sequencing, and mineral beneficiation decisions within a company. Several factors are associated with estimation errors, among them we can highlight the factors associated with sample spacing, the size of production volumes, and the variability of the attribute considered in the estimation. In general, we have that as the spacing between the samples decreases and/or the production volume increases, the error of the estimate tends to decrease and, as the coefficient of variation of the attribute of interest increases, the error tends to increase. To reduce the sample spacing, more financial investments need to be made in drilling, so the optimal spacing that will provide an acceptable estimation error and that is within the company's budget for drilling should always be analyzed.

The access to the estimation error can be done by some geostatistical methods, for example by stochastic simulation, but this is a process that requires knowledge of the technique and takes time. Previous works have proposed a simplified and easily consulted method to access the Maximum Estimation Error (MEE) associated with different types of grade variables, depending on the sample spacing, within small, short-term production volumes and coefficient ranges of specific variation. This dissertation will study the correlations of MEE results already obtained in the literature for short-term volumes with MEE results obtained for long-term volumes, analyzed in this work, aiming to allow quick access to MEE for larger volumes as well.

This dissertation will bring important considerations about the MEE obtained by geostatistical simulation for different sampling patterns and production volumes of the Chapada deposit, Cu-Au type, located in the interior of the state of Goiás. Currently, the use of MEE also for resource classification, within defined production volumes, has been growing in the industry, following the proposal of previous studies. Thus, in this work, correlations will be shown between smaller, short-term volumes and larger production volumes and considerations will be made about these analyzes from the perspective of resource classification.

LISTA DE ILUSTRAÇÕES

Figura 1 - Fluxograma da metodologia	23
Figura 2 - Simulação pelo método "Turning Bands" em 2D.	30
Figura 3 - Diferentes fases da pesquisa mineral e seus estágios.	32
Figura 4 - Classificação de recurso e reserva mineral.....	36
Figura 5 - Critérios geométricos de classificação.	38
Figura 6 - Resultado do MEE para volume de produção de 24x24x4m e faixas de CV de 0,5 – 0,7..	42
Figura 7 - Resultado do MEE para volume de produção de 50x50x4m e faixas de CV de 0,5 – 0,7..	43
Figura 8 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 10 x 10 x valor da composta.	44
Figura 9 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 20 x 20 x valor da composta.	44
Figura 10 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 50 x 50 x valor da composta.	45
Figura 11 - Gráfico do MEE em função de diferentes espaçamentos amostrais, de acordo com Usero (2019)	47
Figura 12 - Localização do depósito de Chapada	49
Figura 13 - Coluna estratigráfica do depósito de Chapada	51
Figura 14 - Seção longitudinal NW-SE do depósito de Chapada, evidenciando os principais corpos e halos de alteração hidrotermal associados.....	52
Figura 15 - Vista em planta da área de estudo considerando o <i>gradeshell</i> de Au (ppm) (A) e o <i>gradeshell</i> de Cu (%) (B).	53
Figura 16 - Domínios de oxidação existentes no corpo analisado	54
Figura 17 - Probability plot para cada variável analisada (A) Au e (B) Cu, considerando os domínios de alteração do depósito.	55
Figura 18 - Divisão da área de estudos quanto ao padrão de espaçamento amostral.....	56
Figura 19 - Histograma para a variável Au com <i>capping</i> (A) e dados desagrupados (B).....	58
Figura 20 - Histograma para a variável Cu com <i>capping</i> (A) e dados desagrupados (B).....	58
Figura 21 - Distribuição no espaço gaussiano para as variáveis Au (ppm) e Cu (%).	59
Figura 22 - Banco de dados com teores de Cu (%) e as direções utilizadas na variografia.	60
Figura 23 - Banco de dados com teores de Au (ppm) e as direções utilizadas na variografia.....	60
Figura 24 - Variogramas no espaço real para os dados de Cu(A) e Au (B).	61
Figura 25 - Validação do histograma das simulações para a variável Cu. (A) Histograma dos dados desagrupados. (B) Histograma acumulado para os dados simulados.....	62
Figura 26 - Validação do variograma das simulações da variável Cu.	62
Figura 27 - Mapa do cenário de referência escolhido para a variável Cu.....	62
Figura 28 - Padrões de malhas de amostragem testados na análise da variável Cu. (A) 100x50m (B) 75x75m (C)75x50m, (D) 50x50m, (E) 50x25m e (F) 30x10m.....	63
Figura 29 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 100x50m.	64
Figura 30 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 75x75m.	64
Figura 31 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 75x50m.	65
Figura 32 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 50x50m.	65

Figura 33 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 50x25m.	66
Figura 34 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 30x10m.	66
Figura 35 - Validação do histograma das simulações para a variável Au.	67
Figura 36 - Validação do variograma das simulações da variável Au.	67
Figura 37 - Mapa do cenário de referência escolhido para a variável Au.	68
Figura 38 - Padrões de malhas de amostragem testados na análise da variável Au. (A) 100x50m (B) 75x75m (C) 75x50m, (D) 50x50m e (E) 50x25m.	68
Figura 39 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 100x50m.	69
Figura 40 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 100x50m.	69
Figura 41 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 75x75m.	70
Figura 42 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 50x50m.	70
Figura 43 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 50x25m.	71
Figura 44 - Corte de seção vertical no modelo de referência da variável Au, mostrando os volumes de produção do ano de 2021.	72
Figura 45 - Gráficos de erros por malha para a variável Au, dentro de cada trimestre.	73
Figura 46 - Gráficos de erros por malha para a variável Cu, dentro de cada trimestre.	74
Figura 47 - Gráficos de erro por malha para a variável Au, dentro dos 5 primeiros anos do LOM.	75
Figura 48 - Gráficos de erro por malha para a variável Cu, dentro dos 5 primeiros anos do LOM.	76
Figura 49 - Gráfico mostrando a média do MEE como função do grid de amostragem para várias faixas de CV, no volume de produção de 50x50x2 metros.	78
Figura 50 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Cu, no estudo 1.	79
Figura 51 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Cu, no estudo 2.	80
Figura 52 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Au, no estudo 1.	80
Figura 53 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Au, no estudo 2.	81
Figura 54 - Médias de MEE(%) para as variáveis Au e Cu dentro do volume médio do trimestre para o ano de 2024.	84
Figura 55 - Médias de MEE(%) para as variáveis Au e Cu dentro do volume médio do trimestre para o ano de 2025.	84
Figura 56 - Análise da variação em % de metal contido para a variável Au no ano de 2024, para as malhas de 50x50 metros e 100x50 metros.	85
Figura 57 - Análise da variação em % de metal contido para a variável Au no ano de 2025, para as malhas de 50x50 metros e 100x50 metros.	85
Figura 58 - Análise da variação em % de metal contido para a variável Cu no ano de 2024, para as malhas de 50x50 metros e 100x50 metros.	86
Figura 59 - Análise da variação em % de metal contido para a variável Cu no ano de 2025, para as malhas de 50x50 metros e 100x50 metros.	86

LISTA DE TABELAS

Tabela 1 - Sumário estatístico para as variáveis Au (ppm) e Cu (%) originais, com <i>capping</i> e com <i>capping</i> e desagrupadas.....	57
Tabela 2 - Média do MEE para a variável Au dentro dos padrões de amostragem, para cada trimestre do ano de 2021.	72
Tabela 3 – Média do MEE para a variável Cu dentro dos padrões de amostragem, para cada trimestre do ano de 2021.	73
Tabela 4 - MEE para a variável Au dentro dos padrões de amostragem, para os 5 anos do LOM desde 2021.....	75
Tabela 5 - MEE para a variável Cu dentro dos padrões de amostragem, para os cinco anos do LOM desde 2021.....	76
Tabela 6 – Coeficientes de variação para Au e Cu dentro dos volumes de produção de cada trimestre do ano de 2021.	77
Tabela 7 - Coeficientes de variação para Au e Cu dentro dos volumes de produção dos primeiros cinco anos do LOM.....	77

Sumário

1 INTRODUÇÃO	21
1.1 Meta	22
1.2 Objetivos	22
1.3 Metodologia	22
1.4 Organização da dissertação.....	24
2 SIMULAÇÃO GEOESTATÍSTICA	25
2.1 Principais tipos de simulação	27
2.1.1 Simulação Sequencial Gaussiana (SGS)	27
2.1.2 Simulação por Bandas Rotativas (<i>Turning Bands</i>)	29
3 AVALIAÇÃO E CLASSIFICAÇÃO DE RECURSOS	32
3.1 Estudos Técnicos	32
3.2 Classificação de Recursos e Reservas Minerais.....	33
3.3 Aspectos Históricos e Evolutivos da Classificação de Recursos	34
3.4 Métodos de Classificação de Recursos.....	36
3.4.1 Continuidade Geológica.....	37
3.4.2 Critérios Geométricos	38
3.4.3 Métodos Geoestatísticos.....	38
3.5 Trabalhos Anteriores Utilizando Simulação Condicional.....	39
4 ESTUDO DE CASO	48
4.1 Localização e Contexto Geológico Regional e Local da Área de Estudo.....	48
4.2 Banco de Dados	52
4.3 Análise de Domínios	53
4.4 Malha de Sondagem	55
4.5 Análise Exploratória e Tratamento Estatístico dos Dados	56
4.6 Análise Variográfica	59
4.7 Simulação Condicional (Cu%).....	61
4.8 Simulação Condicional (Au ppm).....	67
4.9 Definição dos Volumes de Produção.....	71
4.10 Definição dos Coeficientes de Variação.....	77
4.11 Análise de Erro – Longo Prazo x Curto Prazo	77
5 ANÁLISES DENTRO DA CLASSIFICAÇÃO DE RECURSOS.....	83
6 CONSIDERAÇÕES FINAIS.....	88
7 PROPOSTA DE TRABALHOS FUTUROS.....	91
REFERÊNCIAS BIBLIOGRÁFICAS	92

CAPÍTULO 1 - INTRODUÇÃO

Muitas decisões de planejamento, sequenciamento e beneficiamento mineral dentro de uma empresa, são baseadas na estimativa de atributos do depósito mineral, como o teor do elemento de interesse em cada bloco. Dessa forma, erros associados à estimativa de teor irão impactar toda a cadeia produtiva da mina. Usualmente, a estimativa de teores é realizada a partir de amostras espaçadas regularmente dentro um *grid* e, à medida que o espaçamento entre as amostras diminui, o erro da estimativa também tende a diminuir. No entanto, a sondagem é uma atividade que requer investimentos financeiros elevados e, portanto, deve-se analisar o espaçamento ótimo entre furos que vai proporcionar um erro de estimativa aceitável e que esteja dentro do orçamento da empresa destinado à perfuração. Dentre outros fatores que também influenciam o erro da estimativa pode-se destacar: o tamanho do volume de produção considerado para o cálculo do erro e a variabilidade associada ao atributo analisado, por exemplo o teor, essa medida pode ser obtida a partir do cálculo do coeficiente de variação.

Alguns métodos geoestatísticos podem ser utilizados para acessar o erro da estimativa em um dado *grid*, como a utilização dos algoritmos de simulação *Turning Bands* ou *Sequential Gaussian Simulation*. Ambos os métodos utilizam as amostras e seu modelo de continuidade espacial para construir modelos simulados que apresentem variogramas e histogramas similares ao do atributo amostrado. Cada realização da simulação atribui um valor distinto para cada diferente bloco e, portanto, é possível, a partir de todas as simulações geradas para um dado atributo, obter o histograma desse atributo para cada bloco.

Essa dissertação analisará o método proposto por Koppe *et al* (2017) e Koppe *et al* (2019) de obtenção do máximo erro relacionado a estimava (MEE) em função de diferentes espaçamentos amostrais, considerando diferentes volumes de produção possíveis para o longo prazo de um depósito específico do tipo Cu-Au, dentro de diferentes faixas de coeficiente de variação. Nos trabalhos de Koppe *et al* (2017) e Koppe *et al* (2019) a análise foi feita para volumes de produção de curto prazo e gerados gráficos simplificados e de fácil consulta. Para esse trabalho, o MEE será calculado por simulação geoestatística, utilizando o método *Turning Bands*, para diferentes padrões amostrais considerando diferentes volumes de produção de longo prazo, para o depósito de Chapada, localizado no interior de Goiás. Correlações entre os resultados de Koppe *et al* (2019) e volumes de produção maiores serão analisadas, com o objetivo de facilitar o acesso ao MEE para os volumes relacionados ao longo prazo de um depósito.

Os resultados obtidos nessa dissertação serão analisados sob a ótica da classificação de recursos. A classificação de recursos a partir de simulação condicional vem crescendo na indústria e configura-se como métodos mais robustos se comparados, por exemplo, à variância de krigagem, pois incorporam à análise, a incerteza de teores.

1.1 Meta

A meta dessa dissertação é investigar a correlação entre o Máximo Erro da Estimativa (MEE) para volumes de curto prazo (disponível na literatura) e volumes de longo prazo associados a um depósito específico do tipo Cu-Au e analisar como esse tipo de estudo pode auxiliar numa primeira análise sobre a classificação de recursos.

1.2 Objetivos

A fim de atingir a meta proposta, realizou-se um estudo de caso em um depósito real do tipo Cu-Au e os seguintes objetivos foram delineados:

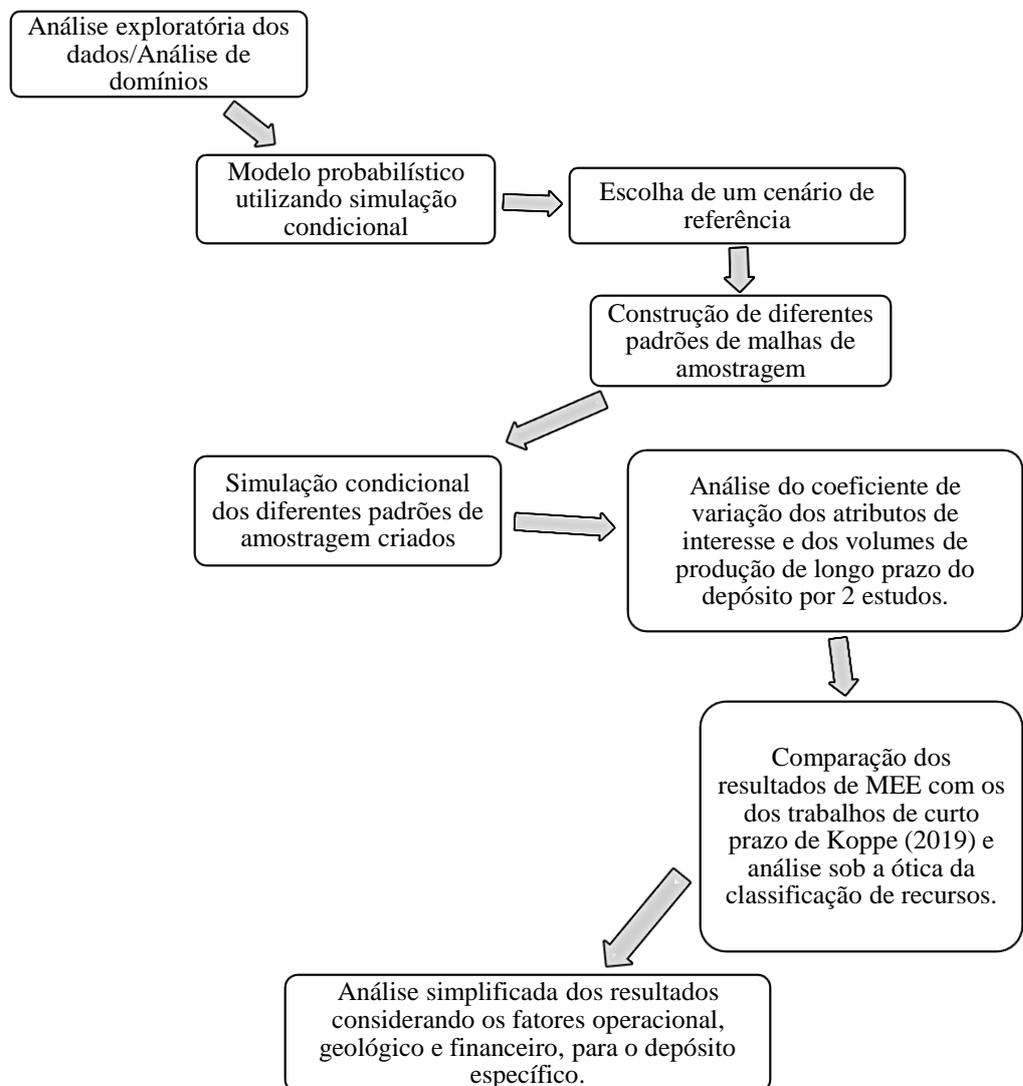
- a) aplicar simulação condicional para a obtenção do erro máximo da estimativa relacionado a diferentes espaçamentos de malhas de sondagem, considerando volumes de longo prazo e diferentes faixas de coeficientes de variação;
- b) analisar a relação entre volumes de produção de longo prazo - este trabalho - e volumes de produção de curto prazo - trabalhos de Koppe et al (2019), para duas variáveis distintas do depósito estudado, dentro das mesmas faixas de coeficientes de variação nos dois estudos;
- c) analisar os resultados relacionados aos objetivos anteriores sob a ótica da classificação de recursos e discutir a otimização da relação custo x risco de adensamento amostral para o depósito desse estudo.

1.3 Metodologia

A metodologia desse trabalho contém cinco etapas principais. Na primeira etapa, foi realizada a análise exploratória dos dados, seguida pela construção de um modelo probabilístico contendo múltiplas realizações geradas por simulação condicional. Na segunda etapa foi realizada a análise da incerteza máxima associada à estimativa para diferentes malhas de sondagem, utilizando o modelo previamente simulado. Na terceira etapa, foi feita a setorização

do depósito quanto aos coeficientes de variação de cada variável, bem como a análise de volumes de produção variados possíveis no longo prazo do depósito e foram gerados resultados de MEE considerando os padrões de amostragem testados na simulação, os volumes de produção e os coeficientes de variação. Na quarta etapa foram analisadas as correlações entre o MEE obtido pelos trabalhos e Koppe et al (2019) para volumes de curto prazo e os volumes maiores de longo prazo, dessa dissertação. Na última etapa a análise dos resultados foi realizada considerando os padrões de classificação de recursos do depósito e foram feitas análises operacionais/financeiras/geológicas associadas à variação da incerteza. O fluxograma da **figura 1** exibe a metodologia aplicada nesse trabalho.

Figura 1-Fluxograma sintetizando as principais etapas do desenvolvimento deste trabalho.



Fonte: Autora.

1.4 Organização da Dissertação

A dissertação está organizada em 6 capítulos:

Capítulo 1 – Introdução ao tema, meta, objetivos e metodologia;

Capítulo 2 – Revisão bibliográfica com conceitos importantes de geoestatística e as principais técnicas de simulação estocástica;

Capítulo 3 – Estado da arte sobre a classificação de recursos e principais trabalhos já desenvolvidos para a otimização de malhas de amostragem com base na incerteza de teores;

Capítulo 4 – Estudo de caso utilizando o banco de dados 3D do Corpo Sul do depósito do tipo Cu-Au de Chapada (Alto Horizonte/GO);

Capítulo 5 – Análise dos resultados sob a ótica da classificação de recursos e considerações finais sobre aspectos financeiros, geológicos e operacionais relacionadas ao estudo;

Capítulo 6 – Considerações finais.

CAPÍTULO 2 – SIMULAÇÃO GEOESTATÍSTICA

Alguns conceitos são fundamentais para o completo entendimento da metodologia aplicada neste trabalho. As variáveis analisadas nesse estudo são variáveis regionalizadas e a metodologia proposta utilizou a simulação estocástica condicional pelo algoritmo *Turning Bands*, a partir da análise do espaço de incerteza associado a um conjunto de realizações.

Variável regionalizada é aquela cuja distribuição dos valores ocorre ao longo de uma região, podendo apresentar uma continuidade no espaço (Matheron, 1963). É comum em vários tipos de depósitos minerais que as variáveis principais ou secundárias, sejam elas de teor ou outras, condicionantes da existência da mineralização, apresentem continuidade de seus valores no espaço, preferencialmente em uma direção que em outras.

Muitos fenômenos naturais podem ser caracterizados pela distribuição espacial de variáveis regionalizadas. Journel e Huijbregts (1978) citam que uma variável regionalizada apresenta, globalmente, um aspecto estruturado e, localmente, um aspecto aleatório. Chilès e Delfiner (1999) salientam que o valor de uma variável regionalizada \mathbf{z} , em um local \mathbf{u} , é considerada uma realização de uma variável aleatória $\mathbf{z}(\mathbf{u})$ e o conjunto de variáveis aleatórias é considerado uma função aleatória (FA).

Outro conceito fundamental da geoestatística e importante para o entendimento das técnicas desenvolvidas nessa dissertação é o conceito de estacionariedade. Armstrong (1998) explica que a estacionariedade é verificada quando todos os momentos estatísticos não variam com a translação. Porém, na prática, apenas os dois primeiros momentos estatísticos são considerados (média e covariância) e, por isso, a hipótese assumida é chamada de estacionariedade de segunda ordem. Já a hipótese intrínseca considera que a média e a variância dos incrementos da função aleatória, para um dado h , existem e são independentes da posição espacial. Os incrementos para cada valor de h , podem ser definidos como a diferença entre o valor da variável aleatória em um local (\mathbf{u}) e o valor da variável aleatória em um local $(\mathbf{u}+\mathbf{h})$. De acordo com McLennan (2007), uma função aleatória estacionária é a representação probabilística de uma propriedade petrofísica com esperança matemática e covariância constantes, independentemente da localização e, dessa forma, é inapropriado considerar a totalidade do depósito mineral como um único domínio estacionário. Geralmente, é necessário identificar diferentes domínios no depósito, cada um com sua função aleatória estacionária.

O entendimento do espaço de incerteza associado ao conjunto de realizações para as dadas variáveis regionalizadas também é fundamental para a compreensão da metodologia aplicada nessa dissertação. O espaço de incerteza associado à distribuição espacial dos valores de um atributo pode ser obtido pela análise dos diversos cenários gerados pelo processo de simulação estocástica (realizações). Cada realização do modelo simulado apresentará uma possibilidade de distribuição de teores de minério que serão lavrados, por exemplo. A análise de diferentes cenários da simulação estocástica pode também fornecer informações sobre a incerteza associada aos valores de uma função de transferência global, por exemplo a tonelagem acima do *cut-off*, na classificação de recursos.

Dentre outros algoritmos capazes de fornecer medidas de incerteza relacionadas a uma variável pode-se citar os métodos lineares e os métodos não-lineares. O primeiro, por exemplo a krigagem ordinária, fornece medidas de incerteza associada a cada estimativa por meio da análise da variância de krigagem, porém a utilização dessa técnica apresenta limitações. Em relação à geoestatística não-linear, temos a krigagem não-linear e a simulação sequencial dos indicadores (SIS). A krigagem não-linear é capaz de fornecer a probabilidade acumulada para valores de um atributo em cada local interpolado e, baseando-se na distribuição de probabilidades obtida com a aplicação desse método, medidas de incerteza associada a um dado valor do atributo (ou estimativa) podem ser geradas (Koppe, 2009).

Os algoritmos de simulação estocástica são mais indicados do que os algoritmos de krigagem para estudos de definição do espaço de incerteza relacionados a um atributo ao longo do depósito. De acordo com Deutsch e Journel (1998), a krigagem visa gerar uma estimativa “ótima” para uma variável em um dado local (u), minimizando a variância do erro de interpolação e gerando uma esperança matemática do erro da estimativa nula. De acordo com Goovaerts (1997) os algoritmos de interpolação a partir de krigagem tendem a suavizar detalhes locais da variabilidade espacial do atributo. Tipicamente, valores baixos são superestimados e valores altos são subestimados. Portanto, mapas de krigagem não são representativos do comportamento global de variáveis da área de mineração, por exemplo o teor. Já os algoritmos de simulação estocástica permitem a geração de diversos cenários da distribuição dos valores de diferentes atributos no depósito mineral. Cada um desses cenários corresponde ao conjunto dos n -valores simulados, em cada realização, e devem honrar os dados originais (amostrais) em seus respectivos locais, apresentar um histograma semelhante ao histograma desagrupado dos dados e apresentar um modelo de continuidade ajustado aos dados originais (Koppe, 2009). Ainda que honrem os dados originais, os cenários simulados raramente apresentam histograma

e variograma idênticos aos dos dados e, segundo Goovaerts (1997) essas flutuações entre a distribuição acumulada e variograma dos dados simulados e originais são chamadas de flutuações ergódicas. Vários fatores influenciam na magnitude das flutuações ergódicas, por exemplo: o aumento de dados originais (diminuem as flutuações) e quanto maior o alcance do variograma em relação ao grid, maiores as flutuações. (Deutsch e Journel, 1992).

De acordo com Deutsch e Journel (1998) os valores simulados em cada local (u) são compostos pelo valor estimado por krigagem no local, adicionado ao valor de erro simulado (resíduo). Dessa forma, na simulação, o erro é responsável pelo aspecto localmente aleatório da variável regionalizada.

2.1 Principais Tipos de Simulação

Os algoritmos de simulação estocástica podem ser classificados em sequenciais e não-sequenciais de acordo com a forma com que garantem a semelhança entre os modelos de continuidade espacial dos valores simulados e o obtido a partir dos dados originais do atributo de interesse (z). O tipo sequencial será mais bem detalhado a seguir.

A simulação sequencial realiza a simulação em cada local (u) do grid, condicionada aos valores dos dados amostrais e aos valores simulados anteriormente, em outros nós do grid, para um dado atributo de interesse. Em cada local a ser simulado o algoritmo de simulação condicional constrói uma ccdf (*Conditional Cumulative Distribution Function*) para os valores do atributo, considerando os dados originais e valores previamente simulados e então sorteia um valor dessa distribuição para o local (u).

Dois dos principais algoritmos de simulação estocástica que podem ser utilizados para o desenvolvimento da metodologia apresentada nessa dissertação, serão a seguir detalhados: a simulação sequencial gaussiana e simulação por bandas rotativas.

2.1.1 Simulação Sequencial Gaussiana (SGS)

De acordo com Goovaerts (1997), considerando a simulação de um atributo contínuo z em N nós de um grid, regular ou irregular, condicionada aos dados, a Simulação Sequencial Gaussiana se procede da seguinte forma:

- a. o primeiro passo é checar a multigaussianidade da função randômica. Para isso, previamente deve-se utilizar a transformação *nscore*, para gerar uma cdf (*conditional distribution function*) normal padrão com os valores do atributo. Posteriormente, checa-se a normalidade de dois pontos da distribuição resultante. Se a hipótese de bigaussianidade for invalidada, outros procedimentos para a determinação de ccdfs locais devem ser considerados, por exemplo, o algoritmo de simulação sequencial dos indicadores.
- b. checada a bigaussianidade da distribuição resultante, precede-se à simulação sequencial, da seguinte forma:
 - i. define-se um caminho randômico, visitando cada nó do grid apenas uma vez;
 - ii. a cada nó do grid, determina-se os parâmetros (média e variância) da ccdf gaussiana usando krigagem simples e o modelo de continuidade, obtido com os dados normalizados. A simulação em cada nó será condicionada por dois tipos de informação: pelos dados amostrais transformados e pelos valores previamente simulados nos nós de grid já visitados.
 - iii. a partir da ccdf em um dado nós do grid, sorteia-se um valor simulado e adiciona-o ao banco de dados. Em seguida, visita-se os outros nós do grid, seguindo o caminho randômico estabelecido e repete-se as etapas anteriores até que os N nós do grid tenham sido visitados.
- c. a etapa final consiste em retro-transformar os valores simulados da variável gaussiana para valores simulados da variável original.

A validação das simulações é realizada a partir da observação dos mapas simulados, histogramas e variogramas da simulação. Espera-se que os dados originais sejam honrados em suas posições, que o histograma simulado reproduza o histograma declusterizado dos dados originais, que os variogramas simulados apresentem flutuações ergódicas próximas ou coincidentes ao modelo de continuidade espacial dos dados originais e que a covariância dos dados seja reproduzida nos modelos simulados em todos os trechos.

2.1.2 Simulação por Bandas Rotativas (*Turning Bands*)

A simulação por bandas rotativas, também conhecido como *Turning Bands* é um método que visa a simplificação de uma simulação no espaço multidimensional ao custo computacional de simulações de linhas no espaço unidimensional. O método consiste em N linhas (1D) concentricamente rotacionadas no espaço 2D ou 3D (Lantuéjoul, 2002). O número de linhas não é um fator limitante no quesito computacional, visto que as simulações em uma direção são extremamente rápidas. O grande gasto computacional fica por conta do condicionamento dos dados (Emery; Lantuéjoul, 2006).

O algoritmo *Turning Bands* realiza a simulação não-sequencial de valores de um atributo z cuja distribuição seja normal padrão. Caso a distribuição do atributo não apresente esse comportamento, deve-se aplicar a transformação não linear *normal score*. Para entender a simulação por bandas rotativas, pode-se imaginar Q linhas concêntricas no espaço. Para um número suficientes de linhas, o modelo de covariância, isotrópico, para uma variável normal (Y) tridimensional, pode ser relacionado ao modelo de covariância para uma variável normal definida em uma dimensão (1D), de acordo com a equação 1 (Matheron, 1973; Journel 1974; Lantuéjoul, 2002).

$$C_3(h) = \frac{1}{Q} \sum_{q=1}^q C_1(< h, q >)$$

(Eq.1)

onde,

$C_3(h)$ = covariância para um par de valores, em 3D, separados por um vetor h;

$C_1(<h,q>)$ = covariância para um par de valores, em 1D, separados pela projeção do vetor h na q-ésima linha que divide o espaço;

Q = Número total de linhas que dividem o espaço.

O algoritmo da simulação por bandas rotativas executa basicamente dois processos: (1) gerar um modelo não condicional respeitando as condições de variabilidade espacial e distribuição de probabilidade original do banco de dados; (2) condicionar a simulação das bandas rotativas através de um pós-processamento usando krigagem (Rossi; Deustsch, 2013).

O método honra os dados de condicionamento e a variabilidade das realizações da simulação incondicional. O condicionamento dos dados é realizado através da krigagem simples dos resíduos (Journel, 1974).

Emery e Lantuéjoul (2006) salientam que, para o procedimento, 1000 é um valor suficiente de linhas, conseguindo atender a maioria dos casos sem gerar artefatos. A simulação realizada com um maior número de linhas apresenta-se mais suavizada.

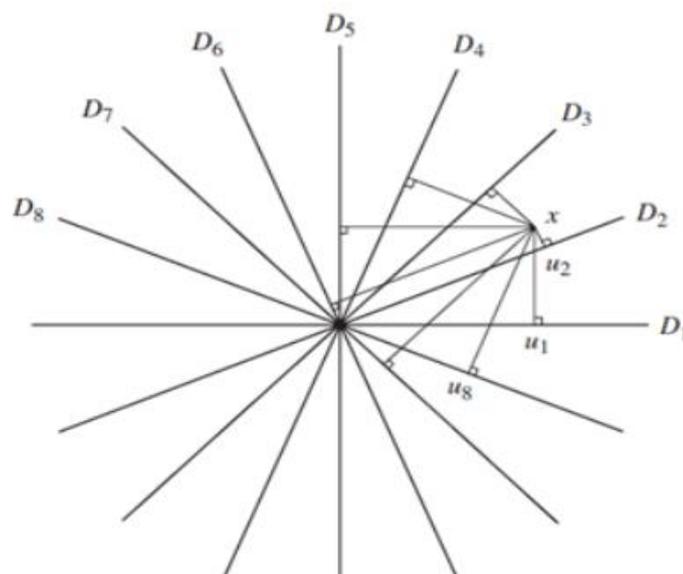
A **figura 2**, extraída de Chilès e Delfiner (2009) exhibe um exemplo de como é realizada a simulação de um ponto x utilizando 8 linhas concêntricas rotacionadas. Para obter o valor simulado de x , deve-se identificar as projeções deste ponto nas 8 linhas dispostas no espaço 2D. Ao ser identificado os valores da projeção, a simulação no ponto x pode ser facilmente obtida pela equação 2.

$$S(x) = \frac{1}{\sqrt{nD}} \sum_{t=1}^{nD} S_t(S_t)$$

(Eq.2)

Onde nD representa o número de bandas rotativas e $S_t(S_t)$ são as simulações não condicionais.

Figura 2 - Simulação do ponto x pelo método *Turning Bands* em 2D.



Fonte: Goovaerts (1997).

Para que sejam realizados os procedimentos de validação da continuidade espacial e da distribuição de frequência do atributo os modelos simulados devem ser retro-transformados para as unidades originais. O método de Bandas Rotativas foi aplicado do desenvolvimento do estudo de caso dessa dissertação.

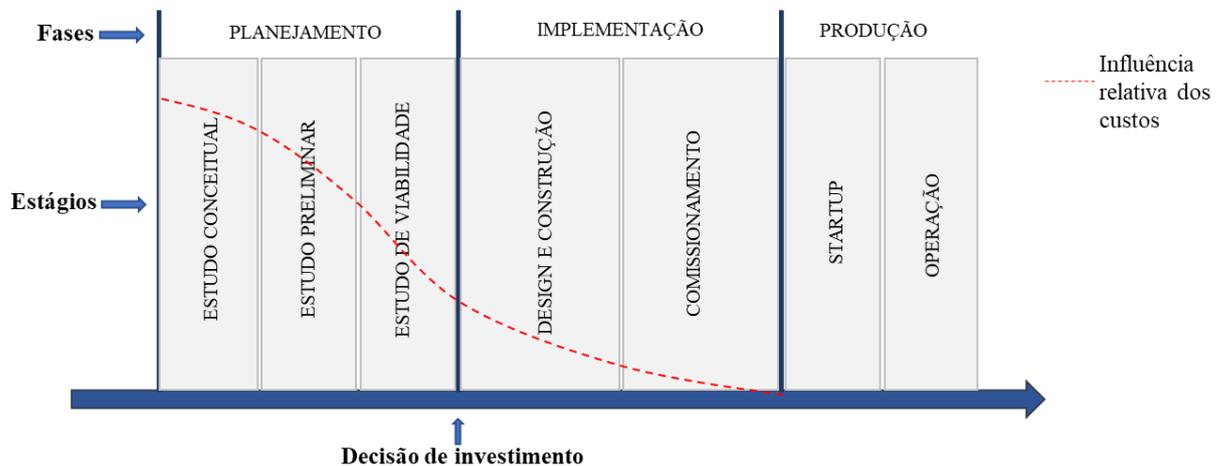
CAPÍTULO 3 – AVALIAÇÃO E CLASSIFICAÇÃO DE RECURSOS

A avaliação de recursos de um depósito mineral costuma iniciar-se nos primeiros trabalhos de escritório e métodos indiretos de pesquisa, como análise de mapas geoquímicos, geofísicos e geológicos, a fim de definir-se alvos regionais. Posteriormente iniciam-se os trabalhos de campo bem como as primeiras campanhas de sondagem exploratória, à fim delimitar-se o alvo de pesquisa. A seguir será feita uma abordagem mais detalhada de cada fase da pesquisa mineral.

3.1 Estudos Técnicos

São chamados de estudos técnicos as fases de detalhamento de uma pesquisa mineral, cada qual com seu nível de precisão. Essas fases são: planejamento, implementação e produção e, cada uma delas, apresenta correlação com a amostragem e com a conversão de recursos. A **figura 3** apresenta uma linha do tempo mostrando a relação entre as diferentes fases e seus estágios.

Figura 3 - Linha do tempo exibindo a relação entre as diferentes fases da pesquisa mineral e seus estágios.



Fonte: Modificado de Rolo (2017).

Na fase do planejamento, as áreas são avaliadas quanto a sua atratividade econômica e exequibilidade técnica. Essa etapa apresenta como resultado um relatório de viabilidade, com a decisão de investimento e continuidade ou não do empreendimento mineiro.

Dentro do planejamento, o primeiro estágio é o estudo conceitual, também chamado de estudo de escopo. Nessa etapa tem-se apenas uma ideia sobre os volumes e distribuição de teores do possível depósito. É acompanhada por alto grau de incerteza e os recursos são predominantemente inferidos. O grau de precisão não é acurado, variando entre 40-50%.

O segundo estágio do planejamento é o estudo de pré-viabilidade, em que se define alguns critérios técnico-econômicos, como o método de lavra e beneficiamento, a serem aplicados. Nessa etapa, busca-se converter o máximo de recursos inferidos em indicados, com malha de sondagem apropriada e o depósito mineral pode ser representado por um modelo de blocos estimado e já pode ser utilizado para um plano de viabilidade econômica.

O último estágio do planejamento é o estudo de viabilidade, onde novas campanhas de sondagem são executadas, a fim de adensar a malha, para garantir um plano de lavra com um menor grau de incerteza para as fases de abertura da mina. A malha deve ser adensada para a conversão de recursos indicados para medidos.

A segunda fase, chamada de implementação, é o período de maior fluxo de caixa, quando a mina e a usina de processamento são desenvolvidas. É constituída pelos estágios de design e construção e pelo estágio de comissionamento.

Por último tem-se a fase de produção, em que a mina entra em operação, o minério é explotado e processado e o produto é vendido no mercado. Nessa etapa, a amostragem é adensada sistematicamente pelo curto prazo da mina, visando garantir previsibilidade na produção diária.

Essa dissertação insere-se no estágio de viabilidade, dentro da fase de planejamento dos Estudos técnicos, com foco nos recursos medidos e ou conversão de recursos indicados para medidos e redução de incerteza sobre a malha de sondagem.

3.2 Classificação de Recursos e Reservas Minerais

De acordo com Chilès *et. al* (2004), a avaliação dos recursos de uma mina é composta de duas etapas. A primeira delas é a delimitação das várias unidades geológicas, correspondentes às diferentes formações geológicas ou diferentes litologias e a segunda corresponde à estimativa e/ou simulação de teores em cada unidade modelada.

A classificação de recursos é o processo pelo qual os blocos estimados são classificados como medidos, indicados ou inferidos, de acordo com o nível de confiança

relacionado às suas estimativas. A qualidade da classificação é pré-requisito para a avaliação dos riscos associados ao depósito (Silva & Boisvert, 2014).

3.3 Aspectos Históricos e Evolutivos da Classificação de Recursos

No ano de 1989 foi publicado o JORC (*Joint Ore Reserves Committee*), o primeiro código australiano para a sistematização de práticas e procedimentos para a classificação de recursos e reservas minerais e definição de diretrizes e dos principais conceitos relacionados à avaliação/classificação de recursos. Posteriormente, outros códigos foram criados em outros países e, em 1997, houve a padronização dos conceitos e terminologias entre os códigos, a partir de um comitê denominado *Council of Mining and Metallurgical Institutions* (CMMI), entre representantes dos conselhos australiano (AusIMM), canadense (CIM), americano (SME) e sul-africano (SAIMM).

Em 2000, o CIM atualiza seu código, o *National Instrument NI43-101*, estabelecendo procedimentos mais rígidos na declaração, ao definir que o recurso medido deve suportar o planejamento de lavra e avaliação econômica do projeto.

Em 1994, através do CMMI, foi fundado o CRIRSCO (Comitê de Reservas Minerais e Padrões Internacionais de Relato) que consiste em um agrupamento de representantes de organizações de diversos países responsáveis pela elaboração de diretrizes gerais para os códigos de declaração de recursos e reservas minerais. Considerado hoje o guia mais atual, as normatizações da CMMI baseiam-se em três pilares fundamentais: Transparência (os relatórios públicos devem apresentar informações claras e transparentes); Competência (O relatório de recursos e reservas deve ser escrito e assinado por um *Competent/Qualified Person*) e Materialidade (todas as informações necessárias para qualquer tomada de decisão devem estar contidas no relatório). Alguns conceitos presentes no documento oficial do CRIRSCO, denominado *Standard Definitions*, são fundamentais para a compreensão do desenvolvimento dessa dissertação e serão a seguir sumarizados:

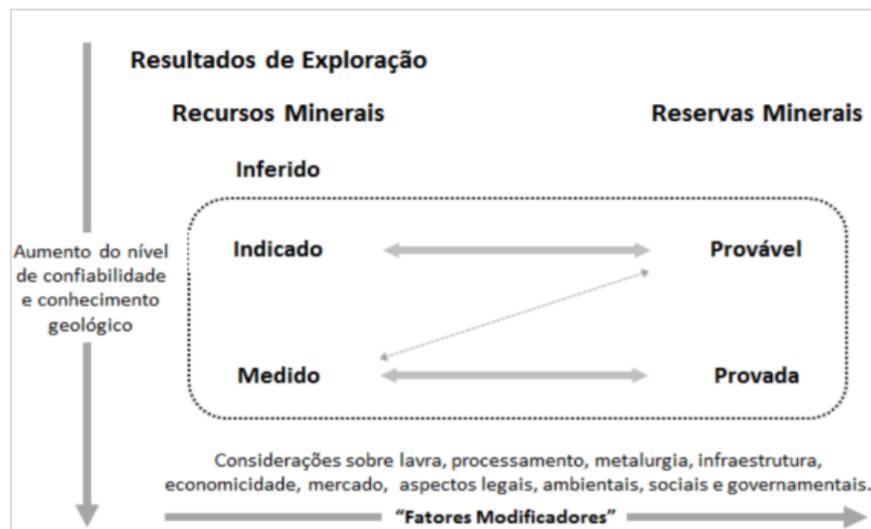
- a) **Recurso mineral:** concentração ou ocorrência de um material sólido de interesse econômico na superfície ou no subsolo cuja geometria, teor (ou qualidade) e quantidade possuem perspectivas razoáveis para eventual extração econômica. Os Recursos mineral podem ser divididos, em ordem crescente de confiança geológica nas categorias de Recurso Inferido, Indicado e Medido.

- b) **Recurso inferido:** é a parte do recurso mineral cuja quantidade e teor (ou qualidade) são estimados com base em evidências geológicas e amostragens limitadas. É baseado na exploração, amostragem e testes coletados através de técnicas apropriadas como afloramentos, trincheiras, pits e furos de sondagem. Possui nível de confiança inferior ao Recurso Indicado e não pode ser convertido em reserva mineral.
- c) **Recurso indicado:** é aquela parte do recurso mineral cuja quantidade, teor (ou qualidade), densidade, geometria e características físicas são estimadas com nível de confiança suficiente para permitir a aplicação e fatores modificadores em detalhe suficiente para suportar um planejamento de lavra e avaliação da viabilidade econômica do depósito. Evidência geológica é derivada de exploração, testes e amostragem detalhada e confiável, coletadas a partir de técnicas apropriadas como furos de sondagem, trincheiras e afloramentos e, com confiança suficiente para assumir continuidade geológica e de teor entre pontos amostrados.
- d) **Recurso medido:** é aquela parte do recurso mineral cuja quantidade, teor (ou qualidade), densidade, geometria e características físicas são estimadas com nível de confiança suficientes para permitir a aplicação de Fatores Modificadores a fim de suportar um planejamento de lavra detalhado e avaliação final da viabilidade econômica do depósito. Evidências geológicas são derivadas de exploração, testes e amostragem detalhada e confiável, coletadas através de técnicas apropriadas como furos de sondagem, trincheiras e afloramentos, e com confiança suficiente para confirmar a continuidade geológica e de teor entre pontos amostrados.
- e) **Reserva mineral:** é a parte economicamente lavrável do Recurso Medido e/ou Indicado, incluindo diluição de material e provisões de perdas. Inclui a aplicação de fatores modificadores.
- f) **Reserva provável:** é a parte economicamente lavrável de um Recurso Indicado e, em algumas circunstâncias, do Recurso Medido. A confiança nos fatores modificadores aplicados a uma Reserva Provável é menor que a aplicada a uma Reserva Provada.

- g) **Reserva Provada:** é a parte economicamente lavrável de um Recurso Medido. Uma Reserva Mineral Provada significa um alto grau de confiança nos Fatores Modificadores.

O Recurso Mineral pode mudar de categoria com base no nível de confiança oferecido, especialmente, pelo adensamento amostral e, a Reserva Mineral pode mudar de categoria com base em fatores modificadores, conforme mostra a **figura 4**.

Figura 4 - Classificação de recurso e reserva mineral.



Fonte: CBRR(2016).

Ainda que os códigos internacionais busquem uniformizar as normas de classificação de recursos e reservas, não há diretrizes sobre qual metodologia ou índice de incerteza deve ser utilizado, ficando à critério de cada profissional definir aqueles métodos que melhor se encaixam no tipo de depósito mineral. De acordo com o JORC (2012), sempre que possível, a classificação de recursos deve vir acompanhada de alguma medida de incerteza.

3.4 Métodos de Classificação de Recursos

De acordo com Souza (2002), são utilizadas várias abordagens para tentar categorizar recursos e reservas minerais, todas voltadas a determinar o teor médio, a tonelagem e o grau de incerteza associado à estimativa. Os principais métodos pelos quais os recursos minerais podem ser classificados durante um projeto de avaliação são frequentemente divididos em dois grupos: (1) critérios ditos tradicionais ou clássicos e (2) critérios com abordagem

geoestatística. A maior parte desses métodos de classificação está baseada na densidade e configuração amostral. Entre os métodos tradicionais pode-se citar:

- a) continuidade geológica;
- b) interpolação vs. extrapolação;
- c) teor de corte;
- d) métodos tecnológicos;
- e) qualidade dos dados;
- f) geométricos;
- g) isolinhas;
- h) área de influência.

Entre os métodos geoestatísticos utilizados para a classificação de recursos pode-se citar:

- a) variância de krigagem;
- b) alcance do variograma;
- c) simulação condicional.

A seguir serão detalhados os métodos tradicionais de continuidade geológica e métodos geométricos e os métodos geoestatísticos de variância de krigagem, alcance do variograma e simulação condicional.

3.4.1. Continuidade Geológica

Compreender a gênese do depósito e a continuidade geológica do volume mineralizado é primordial para a classificação de recursos e reservas minerais. A definição da continuidade física envolve a aquisição e interpretação dos dados, bem como o modelamento do depósito. Para a avaliação de blocos, a continuidade pode ser encarada como uma estimativa da possibilidade da mineralização persistir em cada bloco a ser estimado e é estabelecida com base no conhecimento geológico e na experiência prévia obtida com tipos similares de depósitos. As áreas de interesse seriam então categorizadas como medida, indicada e inferida, de acordo com a apreciação dessa continuidade geológica.

3.4.2. Critérios Geométricos

De acordo com Deutsch *et al.* (2006), os critérios geométricos fornecem medidas diretas de quantidade, densidade e/ou espaçamento de furos. São métodos simples e amplamente utilizados para a classificação e recursos. Os métodos geométricos mais comuns são: malha de sondagem, proximidade do furo ao bloco e densidade de sondagem, conforme apresentado na **figura 5**.

Figura 5 - Critérios geométricos de classificação.



Fonte: Retirado de Saldanha (2020).

Na malha de sondagem, cada bloco é classificado de acordo com o espaçamento entre os furos de sondagem. Este método é particularmente útil quando os furos são verticais e estão espaçados em malhas regulares, pois reduz-se a área para 2D, e a classificação pode ser realizada manualmente através do uso de polígonos. A classificação a partir da medida do raio é feita sobre os blocos individualmente e, nesse método a classificação dos recursos depende não só de um furo, mas de uma continuidade geológica, ou seja, há a necessidade de dois ou mais furos para a aplicação do método (Saldanha, 2020).

3.4.3 Métodos Geoestatísticos

A variância de krigagem é a medida de incerteza produzida a partir da estimativa por krigagem. A krigagem produz estimativas não enviesadas, através da obtenção de pesos que minimizam a variância. As primeiras propostas de classificação de recursos foram baseadas na variância de krigagem e suas variantes, chamadas de variância de krigagem relativas (Dohm, 2005). Entretanto, esse método tem sido cada vez menos empregado na classificação, por fornecer uma medida de incerteza que não leva em conta a variabilidade dos teores (Saldanha, 2020).

No método de classificação utilizando o alcance do variograma, o bloco é classificado a partir de restrições no elipsóide de busca. São realizadas várias passadas de estimativa, cada

uma utilizando um determinado número de amostras e um alcance específico do variograma. Distâncias do alcance máximo do variograma recebem a classificação de indicado e até 70% do variograma, medido. Algumas considerações precisam ser feitas sobre esse método, ainda que amplamente utilizado na indústria, ele não considera o efeito pepita, o uso do modelo exponencial pode gerar distorções na interpretação e não é considerada nenhuma medida de incerteza (Saldanha, 2020).

A classificação de recursos a partir de simulação condicional vem crescendo na indústria e configura-se como métodos mais robustos se comparados por exemplo à variância de krigagem, pois incorporam à análise a incerteza de teores. A seguir, o método será melhor detalhado a partir da análise de alguns trabalhos específicos.

3.5 Trabalhos Anteriores Utilizando Simulação Condicional

Muitos trabalhos na literatura abordaram a utilização de simulação condicional para acesso a incerteza de um atributo de interesse, associando essa incerteza ao espaçamento amostral e variabilidade do atributo.

Pilger (2002) utilizou métodos de simulação geoestatística para acessar a incerteza em cada local de um grid referente a um depósito de carvão. Essa incerteza foi quantificada considerando diferentes índices de incerteza e adição de sondagens adicionais ao grid foi feita nas regiões de elevada incerteza e, com isso, observou-se o efeito de redução da incerteza.

Boucher *et al.* (2004), Sullivan (2003), Li *et al.* (2004, 2005), Richmond *et al.* (2007) e Emery *et al.* (2008) também usam simulação para avaliar a influência da amostragem adicional na redução da incerteza. Sullivan (2003) considerou o desempenho de uma determinada configuração amostral na redução de incerteza sobre a tonelagem, acima do teor de corte. Boucher *et al.* (2004) comparou o desempenho de diferentes malhas regulares (com diferentes espaçamentos entre amostras) na incerteza relacionada à estimativa. Richmond *et al.* (2007) utilizam simulação para mapear os locais de elevada incerteza e, propuseram um algoritmo que adiciona todas as amostras, simultaneamente, nessas regiões de maior incerteza. Li *et al.* (2004, 2005) avaliaram o desempenho de diferentes malhas regulares a partir de um algoritmo e, ressaltam que diferentes espaçamentos de malhas devem ser utilizados em áreas com diferentes variabilidades para o atributo de interesse. E, Emery *et al.* (2008) apresentou um algoritmo que permite testar diferentes configurações amostrais onde a posição das amostras é irregular, possibilitando a aproximação da incerteza associada a cada bloco.

Koppe (2009) analisa a eficiência de duas configurações amostrais quanto à redução de incerteza sobre uma função de transferência e elabora um algoritmo que pode ser executado em software da indústria da mineração, construindo automaticamente as configurações analisadas. Koppe (2009) aplica a simulação para a melhoria na eficiência de locação e configuração amostral. Verly *et al* (2014) define a malha de sondagem com base em suporte e precisão. Outros autores como Souza (2002), Dohm (2005), Snowden (1996) e Rossi & Camacho (2001) também tratam sobre o tema.

Três trabalhos relevantes presentes na literatura serão mais bem detalhados a seguir, pois compõem a base de produção dessa dissertação: “*A Chart for Judging Optimal Sampling Spacing for Ore Grade Estimation*”, Koppe *et al* (2017) e Koppe *et al* (2019), partes I e II, respectivamente e, “*An approach for drilling pattern simulation*”, de Usero *et al* (2019), que utiliza como base o trabalho de Verly *et al* (2014).

Em Koppe *et al* (2017) a média do máximo erro da estimativa de teores de cada bloco foi analisado em função do espaçamento do grid, dos volumes de produção de curto-prazo e das faixas de coeficientes de variação do atributo de interesse. Na parte I, vários padrões de espaçamento de grid e volumes de produção foram testados para dois atributos de diferentes depósitos, Au (ppm) e Ni (%) e, foram investigados apenas os resultados de incerteza da estimativa de regiões com a mesma variabilidade de teor (medida obtida a partir do cálculo do coeficiente de variação). Concluiu-se que, para diferentes atributos de interesse, se o modelo de continuidade espacial desses atributos for semelhante, as regiões com coeficiente de variação similares apresentarão incertezas similares para espaçamentos de grid e geometrias de blocos semelhantes. Esse estudo gerou gráficos de análise simples para uma primeira interpretação a respeito do máximo erro relacionado à estimativa.

A metodologia utilizada nesse estudo consistiu em realizar a simulação dos atributos de interesse utilizando o algoritmo de simulação condicional *Turning Bands*, gerando um cenário de referência que foi utilizado para criar diferentes grids com diferentes espaçamentos amostrais. Para isso, em cada nó do grid, para cada padrão de espaçamento desejado, foi coletada uma informação que foi considerada como um dado coletado e, em seguida, foi adicionada a um banco de dados. Para cada grid virtual criado, realizou-se também a simulação estocástica pelo método *Turning Bands*, condicionada ao banco de dados previamente criado. Para o Au (ppm) e Ni (%) foram geradas 80 realizações (número considerado suficiente para acessar a incerteza da estimativa em ambos os casos). Para o Au (ppm) utilizou-se um modelo de blocos de 2 x 2 x 1 metros e para o Ni (%), 2,5 x 2,5 x 1

metros, tanto para o cenário de referência quanto para as simulações para acesso à incerteza. As malhas testadas foram 12 x 12 x 1 metros, 24 x 24 x 1 metros e 50 x 50 x 1 metros para o Au (ppm) e 12.5 x 12.5 x 1 metros, 25 x 25 x 1 metros e 50 x 50 x 1 para o Ni (%). Foram testadas também diferentes geometrias de blocos referentes ao curto prazo da mina. Para o Au (ppm) foram testados os blocos de 10 x 10 x 4 metros, 24 x 24 x 4 metros e 50 x 50 x 4 metros e para o Ni (%) foram testados os blocos de 10 x 10 x 4 metros, 25 x 25 x 4 metros e 50 x 50 x 4 metros. O número de valores simulados dentro de cada bloco foi analisado para fazer uma aproximação da média de todo o bloco.

Para obter-se o máximo erro da estimativa para o bloco $MME(i)$, utilizou-se neste trabalho a equação 3.

$$MME(i) = \frac{[Q95(i) - Q5(i)]}{2 E_{type(i)}}$$

(Eq.3)

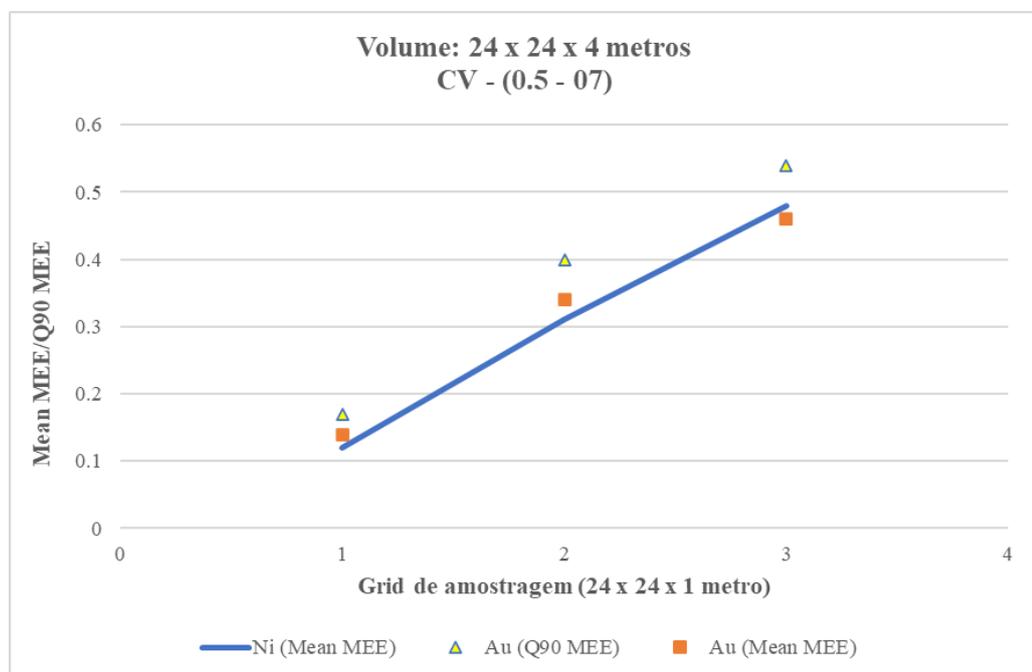
Onde $Q95(i)$ e $Q5(i)$ são os percentis de 5% e 95% das simulações para um bloco i e o $E(type)$ é a média dos valores simulados para o bloco i . Essa média é equivalente ao valor estimado para o bloco i se o algoritmo de interpolação por krigagem tivesse sido usado (Matheron, 1963). Na equação 3, o numerador ($Q95(i) - Q5(i)$) foi utilizado para delimitar um intervalo de 90% de confiança e, supondo-se que o valor estimado real esteja no centro da distribuição, tem-se que o erro máximo possível associado à estimativa é esse intervalo dividido por 2. Adicionalmente, divide-se o valor máximo do erro pela estimativa do valor real (aproximado pelo $E(type)$), para representar o erro máximo como uma proporção do estimado. Para esse estudo observa-se que o $E-type$ se encontra no centro da distribuição.

O coeficiente de variação foi calculado dividindo-se o desvio padrão dos valores dos pontos simulados dentro dos blocos no volume de produção de 50 x 50 x 4 metros pela média desses valores, considerando o cenário de referência. Nesse estudo, para outras geometrias de blocos testadas, o CV não foi recalculado. O coeficiente de variação provê a variabilidade medida por região em cada bloco. Por fim, criou-se para o Au (ppm) um gráfico mostrando o MEE em função do grid de amostragem, para cada geometria e CV testado e inseriu-se os valores de Ni (%) nesse mesmo gráfico a fim de verificar-se que mesmo para diferentes atributos, regiões com coeficientes de variação similares tendem a apontar incertezas de estimativa similares para os mesmos volumes de produção e grids de amostragem.

As **figuras 6 e 7** apresentam parte do resultado desse trabalho, dois gráficos modificados dos resultados originais, mostrando a média do MEE em função do grid de amostragem, para diferentes geometrias de bloco possíveis para o curto prazo das minas estudadas, em diferentes faixas de CV. O Q90 MEE se refere ao limite a partir do qual 90% dos blocos apresentam seus MEE abaixo. A partir da **figura 7** pode-se interpretar, por exemplo, que se o teor de Au (ppm) em um bloco de 50 x 50 x 4 metros for estimado, utilizando um grid de 24 x 24 x 1 metros e esse bloco apresentar um coeficiente de variação entre 0.5 e 0.7, é esperado que o valor real para essa estimativa do bloco seja de mais ou menos 15% do valor estimado, com 90% de probabilidade.

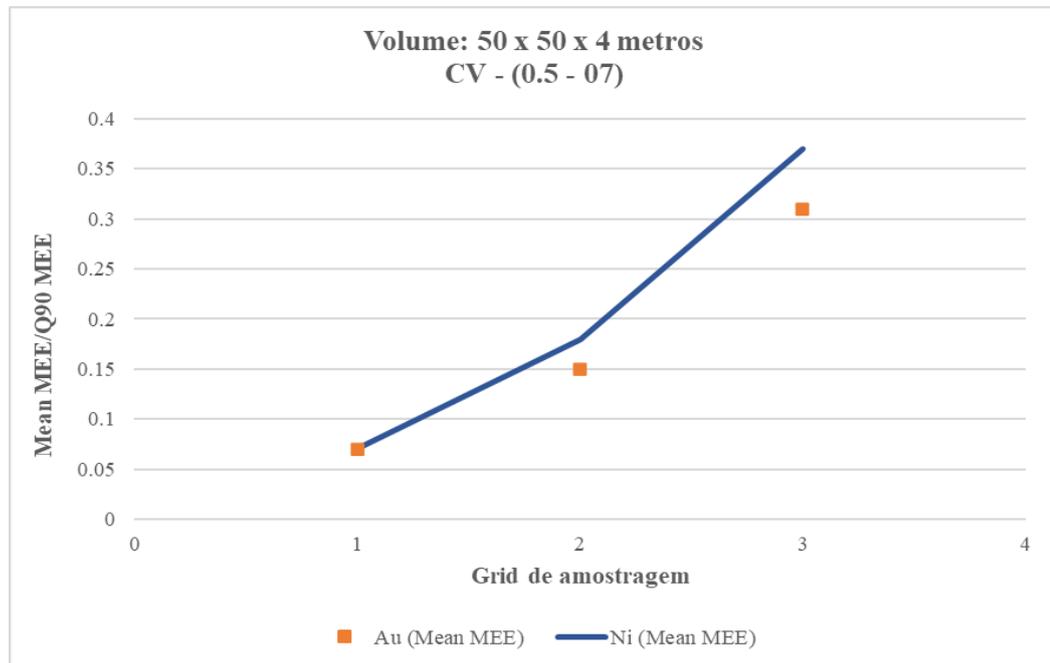
As **figuras 6 e 7** mostram também que para cada grid de amostragem e geometria de bloco testada (e para o mesmo intervalo de CV), o MEE encontrado para o Au(ppm) é menos de 8% diferente do MEE para o Ni (%), o que mostra que incertezas similares são obtidas para regiões de CVs, geometrias de blocos e grids de amostragem semelhantes, mesmo considerando-se atributos completamente distintos.

Figura 6 - Resultado do MEE em função do grid de amostragem, para o volume de produção de 24 x 24 x 4 m e faixas de CV de 0.5 – 0.7.



Fonte: Modificado de Koppe (2017).

Figura 7 - Resultado do MEE em função do grid de amostragem, para o volume de produção de 50 x 50 x 4 m e faixas de CV de 0.5 – 0.7.

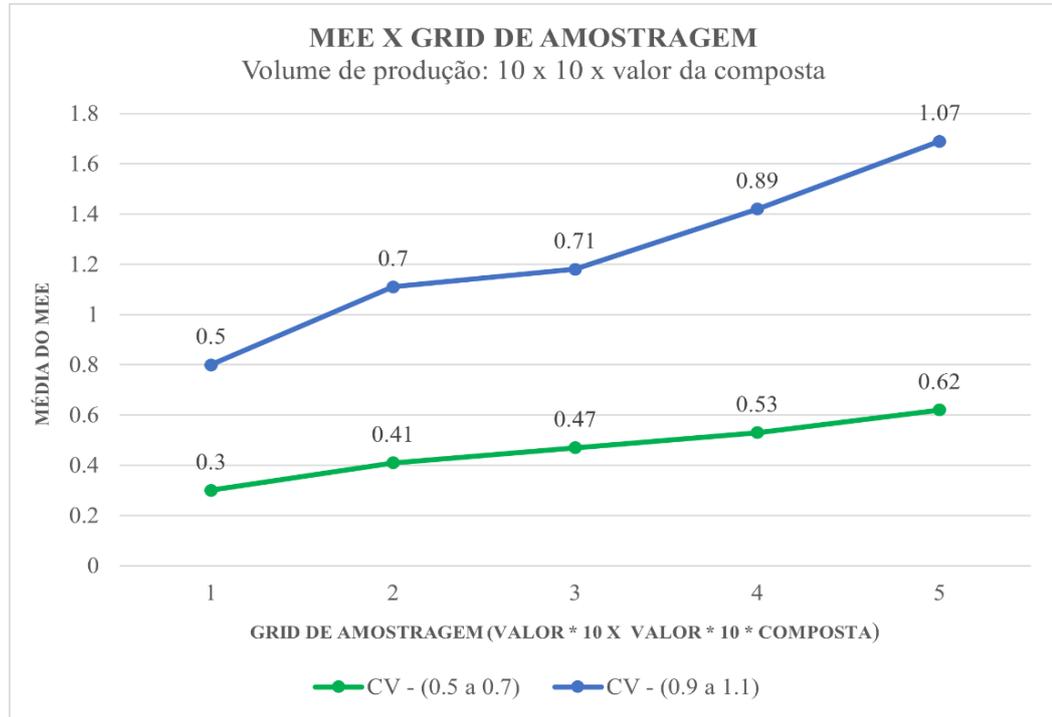


Fonte: Modificado de Koppe (2017).

Em Koppe *et al* (2019), foram apresentados resultados considerando a mesma metodologia do trabalho anterior, porém para outros atributos, Cu (%), Al (%) e Fe (%) e dois atributos sintéticos, A e B, extraídos da simulação não condicional. As **figuras 8, 9 e 10** apresentam as médias do MEE como função do grid de amostragem para várias faixas de coeficiente de variação e geometrias de blocos também possíveis no curto prazo dos depósitos analisados. Para esse estudo, foi utilizado um tamanho de composta vertical correspondente ao tamanho do bloco em z.

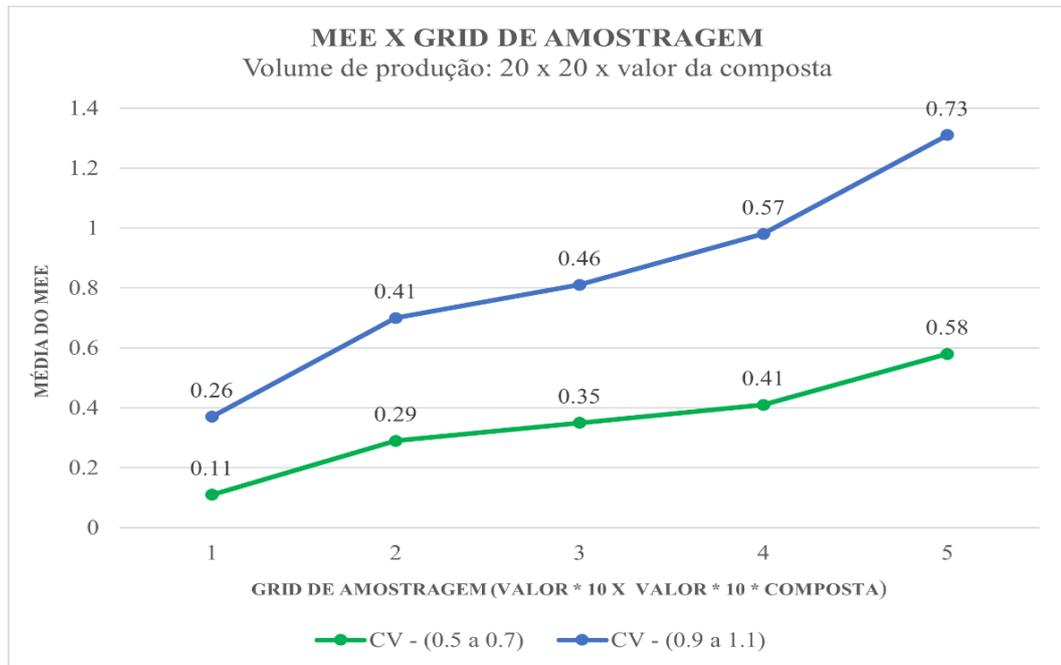
A partir dos gráficos observa-se que a relação entre o grid de amostragem e o máximo erro da estimativa é aproximadamente linear para o mesmo coeficiente de variação e geometria de bloco. Quanto maior a faixa do CV analisada maior o coeficiente angular das linhas nos gráficos, ou seja, quanto maior o CV, maior o MEE e maior a variabilidade dessa incerteza. Observa-se também, como esperado, que quanto maior o suporte, ou seja, o volume do bloco analisado, menor o MEE. É possível observar também que o tamanho do bloco em z não influencia nos resultados se a composta vertical for idêntica.

Figura 8 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 10 x 10 x valor da composta.



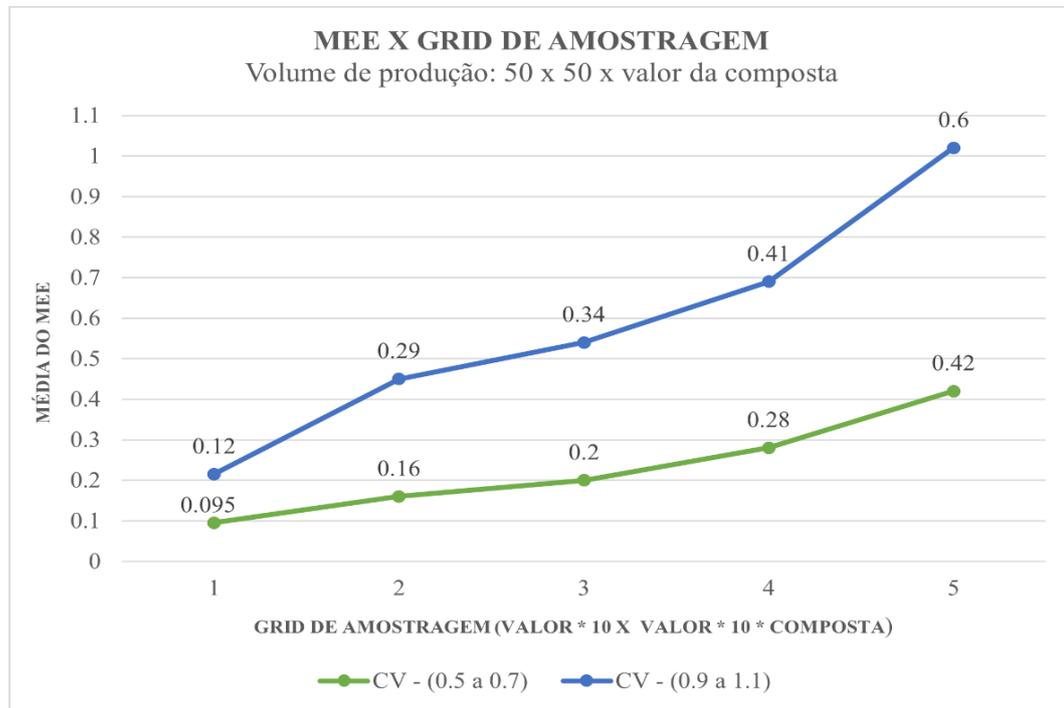
Fonte: Modificado de Koppe (2019).

Figura 9 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 20 x 20 x valor da composta.



Fonte: Modificado de Koppe (2019).

Figura 10 - Média do MEE como função do grid de amostragem para duas diferentes faixas de CVs e geometria de bloco de 50 x 50 x valor da composta.



Fonte: Modificado de Koppe (2019).

Por fim, Usero (2019) apresenta uma metodologia de simulação de grids de amostragem associada à classificação de recursos minerais proposta por Verly (2014), que utiliza simulação condicional e o conceito de intervalo de confiança e volumes de produção para o cálculo da incerteza associada à estimativa de teores de um depósito específico. Essa metodologia vem sendo aplicada em diferentes minas em operação e para diferentes commodities, como ferro, ouro, cobre e bauxita. A partir dessa técnica é possível prever o risco associado à determinados espaçamentos de malha e suportar decisões a respeito da necessidade ou não de novas campanhas de sondagem para a conversão de recursos, seja para indicado ou medido.

O estudo foi completamente desenvolvido no software Isatis® e consistiu em basicamente três etapas:

- a) aplicação de simulação condicional (método *Turning Bands*) no banco de dados e criação de diferentes cenários;

- b) escolha de um cenário de referência é escolhido e, a partir dele, realiza-se a geração de malhas de furos virtuais em diferentes espaçamentos de amostragem;
- c) a simulação condicional é realizada em cada padrão de amostragem com o objetivo de obter-se a dispersão referente ao atributo simulado em um intervalo de confiança de 90%, considerando a produção mensal do trimestre e a produção anual.

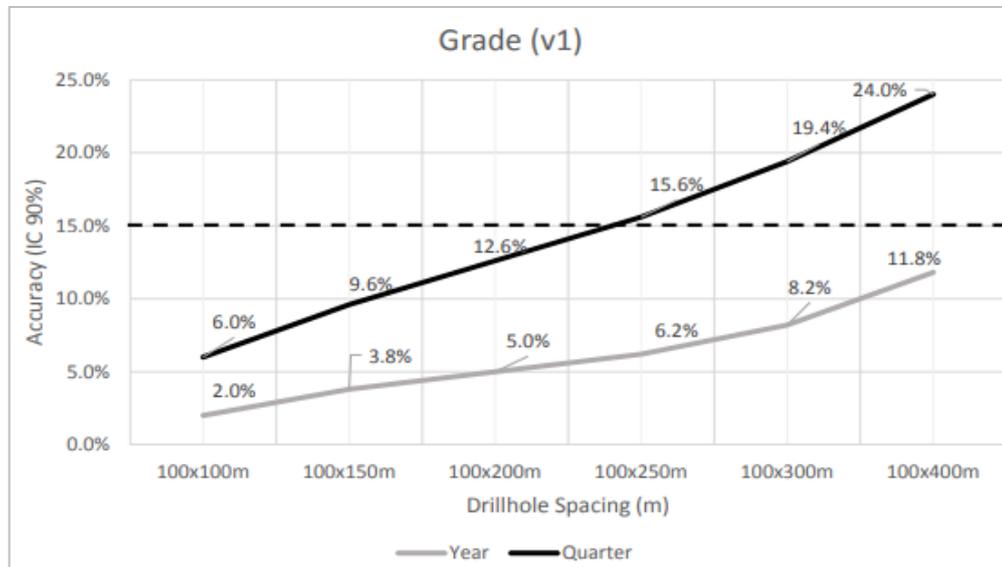
De acordo com a metodologia proposta por Verly (2014), a classificação de recursos utiliza o conjunto de simulações para obter a incerteza da estimativa associada ao elemento de interesse no depósito, utilizando as seguintes regras:

- a) Recurso medido: $\pm 15\%$ com 90% de intervalo de confiança no volume de produção do trimestre (3 meses);
- b) Recurso indicado: $\pm 15\%$ com 90% de intervalo de confiança no volume de produção anual.

Como resultado da aplicação desse estudo, a companhia pode definir o espaçamento ótimo que suportará a classificação de recursos específica do depósito.

Para esse artigo foi utilizado um banco de dados de 388 furos e 5801 amostras e analisou-se duas variáveis de interesse: o teor (v1) e a espessura da camada (v2). Para exemplificar os resultados obtidos, a **figura 11** mostra o gráfico obtido para a análise da incerteza em função de diferentes espaçamentos de amostragem. Aqui a acurácia dentro de um intervalo de 90% é calculada de forma idêntica à equação 3.

Figura 11 - Gráfico da média da acurácia sobre a média da estimativa dentro de um intervalo de confiança de 90% para a variável de teor (v1), nos volumes de produção de trimestre (suportando o recurso medido) e do ano, suportando o recurso indicado.



Fonte: Retirado de Usero *et al* (2019).

De acordo com a **figura 11** e com a metodologia proposta por Verly (2014), o espaçamento amostral de 100x200 metros é suficiente para classificar o recurso como medido e o espaçamento amostral de 100x400 metros é suficiente para classificar o recurso como indicado, no depósito em questão.

O setor de mineração, em cada uma de suas *commodities* e empreendimento mineiros movimenta muitos investimentos e é, portanto, fundamental quantificar-se o nível de confiança associada à estimativa e classificação de recursos e para isso é necessário prever a quantidade ótima de furos, a partir da qual pode-se estimar com confiança aceitável o conhecimento geológico entre eles.

CAPÍTULO 4 – ESTUDO DE CASO

O estudo de caso dessa dissertação foi realizado com os dados do depósito de Chapada, do tipo pórfiro Cu-Au, localizado a noroeste do estado de Goiás. Este depósito foi descoberto em 1973 pela INCO Ltda durante campanha de exploração regional, em que sedimentos de corrente indicaram a ocorrência de ouro na área e, assim, foi largamente pesquisado e sondado por diversas empresas na década de 1990. Em julho de 2003, o depósito de Chapada foi adquirido pela empresa Yamana Gold, ainda com foco na produção de ouro e, em julho de 2020 o depósito passou para o controle da multinacional Lundin Mining, com foco na produção de polimetálicos.

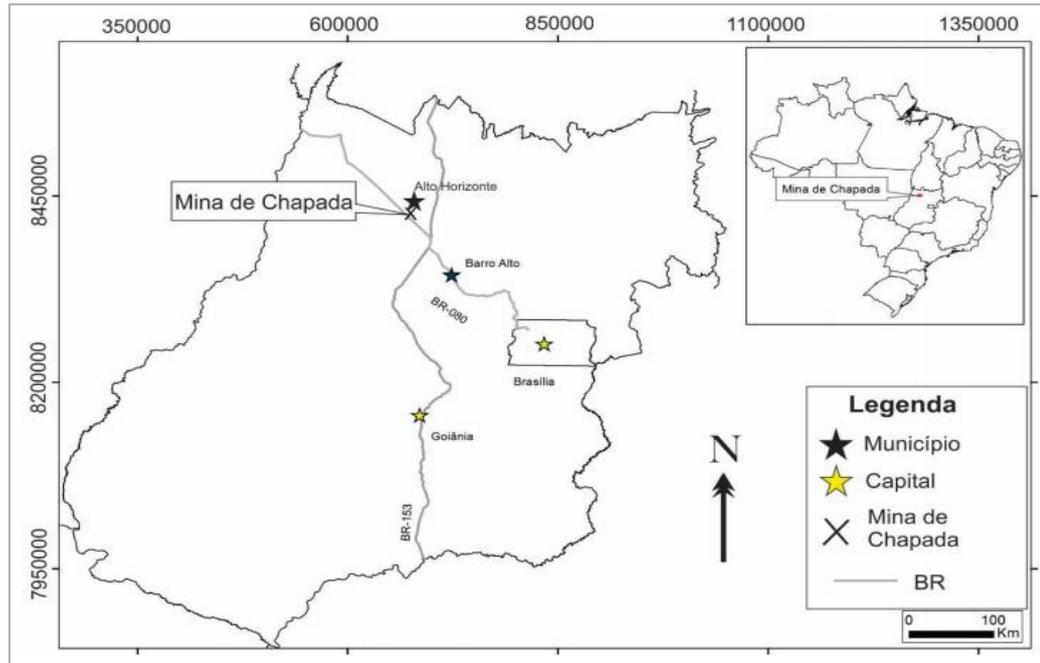
4.1 Localização e Contexto Geológico Regional e Local da Área de Estudo

Depósitos de cobre do tipo pórfiro, são importantes sistemas magmáticos-hidrotermais e representam as principais fontes de Cu do planeta. Caracterizam-se por apresentarem grandes tonelagens ($10^6 - 10^9$ t), baixos teores (0,7% a 1,1% Cu) e, por vezes, são acompanhados dos subprodutos Mo, Au e Ag (Sinclair, 2007; Sillitoe, 2010).

Grande parte desses depósitos ocorrem em cinturões orogênicos pós-paleozoicos. Contudo, nas últimas décadas, vários sistemas bem mais antigos, datando do pré-cambrianos, foram reconhecidos, entre eles o depósito de Chapada. Por serem mais velhos, sofreram mais metamorfismo e intemperismo e, o seu reconhecimento e registro é por vezes dificultado pelos processos erosivos (Sinclair, 2007; Sillitoe, 2010).

O depósito magmático-hidrotermal do tipo Cu-Au de Chapada está localizado a 3 km do município de Alto Horizonte (GO), 320 km a norte de Goiânia e 270 km ao noroeste de Brasília (**figura 12**) e é a principal jazida mineral encontrada no Arco Magmático de Mara Rosa.

Figura 12 - Localização do depósito de Chapada – 3 km de Alto Horizonte, norte do estado de Goiás.



Fonte: Retirado de Pian (2017).

Considerando o contexto geológico regional da área de estudo, o depósito de Chapada está localizado na Província Tocantins, reconhecida como um sistema orogênico neoproterozoico que teria se desenvolvido nos eventos colisionais de amalgamação do supercontinente Gondwana (Almeida *et al.*, 1977). A Província Tocantins está limitada entre o cráton amazônico, a oeste, o cráton São Francisco, a leste, a Bacia do Parnaíba, a norte e a Bacia do Paraná, a sul (Valeriano *et al.*, 2004). Apresenta 2000 km de comprimento e 800 km de largura em um *trend* principal norte-sul e é composta por três faixas orogênicas: Faixa Brasília, a leste e Faixas Araguaia e Paraguai, a oeste.

A Faixa Brasília é uma sequência espessa de rochas metassedimentares com uma grande influência de rochas vulcânicas de um arco neoproterozoico juvenil, denominado Arco Magmático de Goiás (Valeriano *et al.*, 2004; Almeida *et al.*, 1977), onde está localizado o depósito de Chapada, mais especificamente dentro de um de seus domínios principais, o Arco Magmático de Mara Rosa. A área de estudo é estruturalmente complexa e apresenta como principal estrutura regional a zona de cisalhamento Rio dos Bois, na região de Alto Horizonte, que está fisicamente delineada por um rio de mesmo nome, Rio dos Bois. Corresponde a uma zona de cisalhamento reversa, com obliquidade alta e disposição geral N20-40E/20-40NW, com transporte tectônico para SE, sentido cráton São Francisco (Oliveira *et al.*, 2007). A falha Rio

dos Bois é a principal estrutura relacionada à remineralização do depósito de Chapada (Oliveira, 2015).

Considerando o contexto geológico local da área de estudo, a estruturação do corpo de minério de Chapada corresponde a uma grande dobra anticlinal aberta, com flancos constituídos por rochas metavulcânicas, metapiroclásticas, metavulcanoclásticas, metassedimentares imaturas e metassedimentares químicas, e núcleo composto por metadiorito equigranular a porfirítico (Oliveira *et al.*, 2015). A **figura 13** apresenta a coluna estratigráfica do depósito, evidenciando a dobra especialmente pelo surgimento na estratigrafia das camadas A e C, cuja composição litológica é muito semelhante, bem como os domínios de alteração hidrotermal. A porção central da dobra é caracterizada pela camada B, mineralizada e hospedeira dos principais corpos de Chapada.

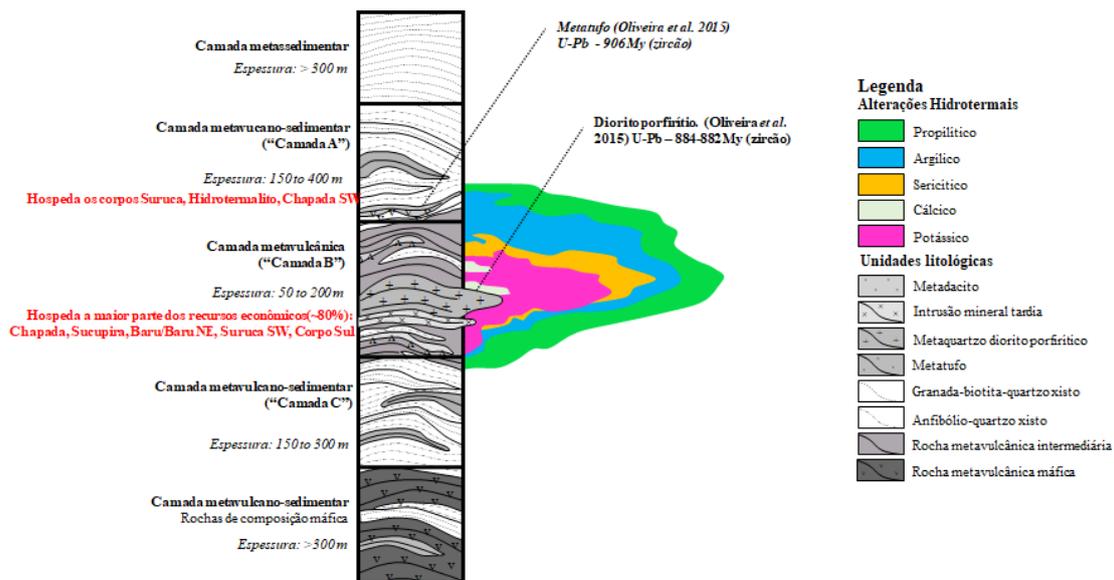
Os litotipos que hospedam o minério são essencialmente metapelitos e metavulcânicas (Richardson *et al.*, 1986; Oliveira *et al.*, 2015). O minério é caracterizado por calcopirita disseminada e é hospedado por biotita xisto (biotita xisto, muscovita-biotita xisto, anfibólio-biotita xisto) e subordinadamente por biotita gnaiss, muscovita xisto e cianita-muscovita xisto, sendo o biotita xisto o principal hospedeiro da mineralização. A parte central do pórfiro, altamente mineralizada é composta especialmente por um metaquartzo diorito porfirítico (presente na camada B). As rochas encaixantes (não mineralizadas ou pobres em sulfetos) são principalmente metadioritos e anfibolitos.

O minério cupro-aurífero consiste em uma associação de sulfetos disseminados (pirita e calcopirita, principalmente) e óxidos (magnetita, hematita, ilmenita e rutilo), no qual a calcopirita é o principal mineral econômico. O ouro tem dimensão micrométrica e, em sua maioria, ocorre incluso em calcopirita e, subordinadamente, em pirita ou em bordas de sulfetos. Outros minerais metálicos, com ocorrência subordinada, dizem respeito à bornita, calcocita, galena, pirrotita, esfalerita e molibdenita. O minério ocorre predominantemente disseminado, ao longo dos planos de foliação (ou superfícies axiais de dobras) e, subordinadamente em concentrações maciças nas charneiras de dobras ou em fraturas. De maneira geral, o corpo mineralizado tem um zoneamento definido por um núcleo rico em calcopirita-magnetita, que possui maiores teores de cobre e ouro, hospedado no biotita-xisto, envolto por uma associação de calcopirita-pirita, ocorrendo em muscovita xisto e cianita xisto (Richardson *et al.*, 1986; Oliveira *et al.*, 2015).

O depósito apresenta as típicas alterações hidrotermais e zoneamento do tipo Cu-Au pórfiro. As rochas mais ricas em cianita são interpretadas como produto metamórfico de uma alteração hidrotermal argílica e é a alteração hidrotermal mais superficial e amplamente distribuída no depósito de Chapada. As rochas ricas em biotita são representativas da alteração hidrotermal potássica, identificada apenas em testemunhos de sondagem e em grandes profundidades no *open pit* da mina. É a alteração que acompanha as zonas mineralizadas de maiores teores e com importância econômica. A associação de xistos ricos em quartzo e muscovita é interpretada com diagnóstico da alteração sericítica. Por fim, o contexto do entorno do depósito de Chapada, em porções distais ao minério de alto teor, contém rochas ricas em anfibólio e epidoto, interpretadas como representantes do produto de alteração propilítica (Oliveira *et al.*, 2015). A **figura 14** apresenta uma seção longitudinal NW-SE do depósito, exibindo as principais alterações hidrotermais associadas aos principais corpos do depósito.

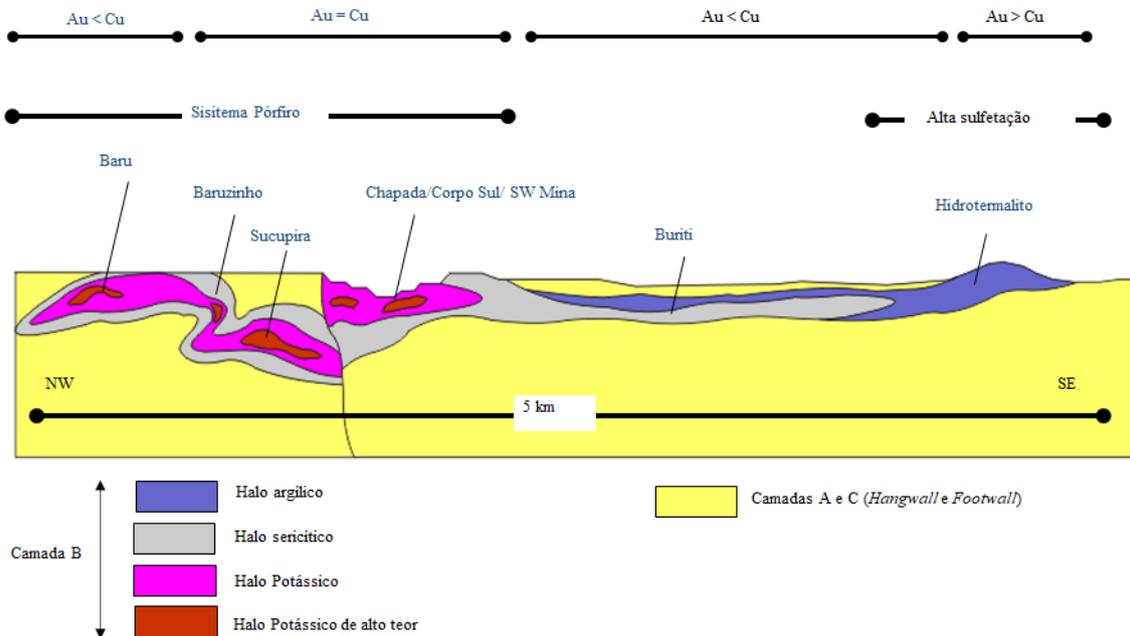
A partir da **figura 14** é possível observar que os corpos Baru, Baruzinho, Sucupira, Chapada, Corpo Sul e SW Mina representam a porção principal do sistema pórfiro, concentrado especialmente na camada B. Do centro para as bordas do sistema pórfiro tem-se o halo potássico de mais alto teor, halo sericítico, halo argílico, que seguem uma ordem decrescente quanto ao teor e quantidade da mineralização.

Figura 13 - Coluna estratigráfica do depósito de Chapada, evidenciando a dobra pelo surgimento na estratigrafia das camadas A e C.



Fonte: Modificado de 'Exploration team presentation, 2020', Lundin Mining.

Figura 14 - Seção longitudinal NW-SE do depósito de Chapada, evidenciando os principais corpos e halos de alteração hidrotermal associados.



Fonte: Modificado de 'Exploration team presentation, 2020', Lundin Mining.

O entendimento das complexidades geológicas do depósito, especialmente relacionadas à estrutural e alterações hidrotermais são fundamentais para as conclusões posteriores do trabalho.

Este trabalho foi desenvolvido no Corpo Sul do depósito.

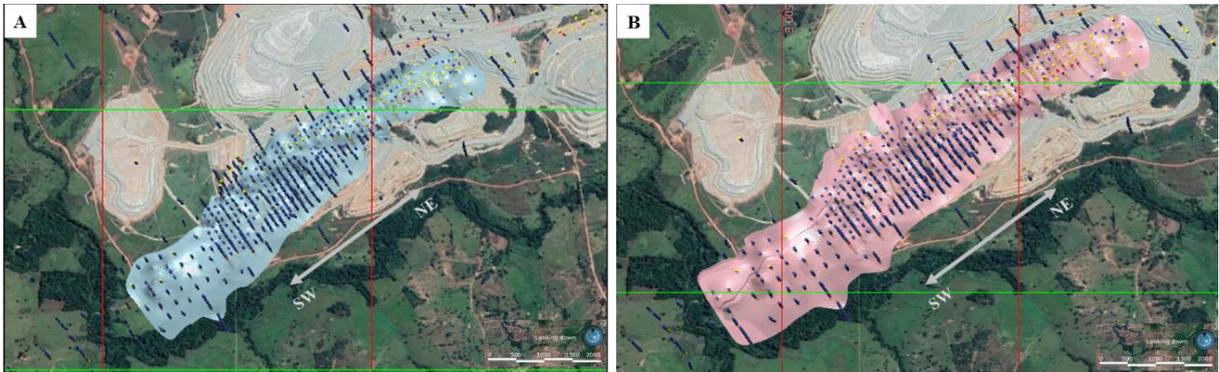
4.2 Banco de Dados

O estudo dessa dissertação foi desenvolvido separadamente para as duas principais variáveis de interesse do depósito: Au (ppm) e Cu (%). A seleção de amostras foi realizada dentro de modelos criados para cada variável (**figura 15**). Esses modelos foram modificados do *gradeshell* original de cada elemento (Au e Cu), utilizados para como base para os cálculos de recurso da empresa. O *gradeshell* é a envoltória que delimita a mineralização e, para o caso desse depósito, no momento desse trabalho foi modelado considerando teores iguais ou maiores que 0.07 ppm de Au e 0.1 % de Cu.

A criação dos novos modelos objetivou reduzir a área de trabalho do estudo, considerando apenas os furos no interior do Corpo Sul da mina (área de interesse), dentro da

envoltória mineralizada e contemplando o sequenciamento dos possíveis planos de lavra definidos do ano de 2021 até o ano de 2025.

Figura 15 - Vista em planta da área de estudo considerando o *gradeshell* de Au (ppm) (A) e o *gradeshell* de Cu (%) (B).



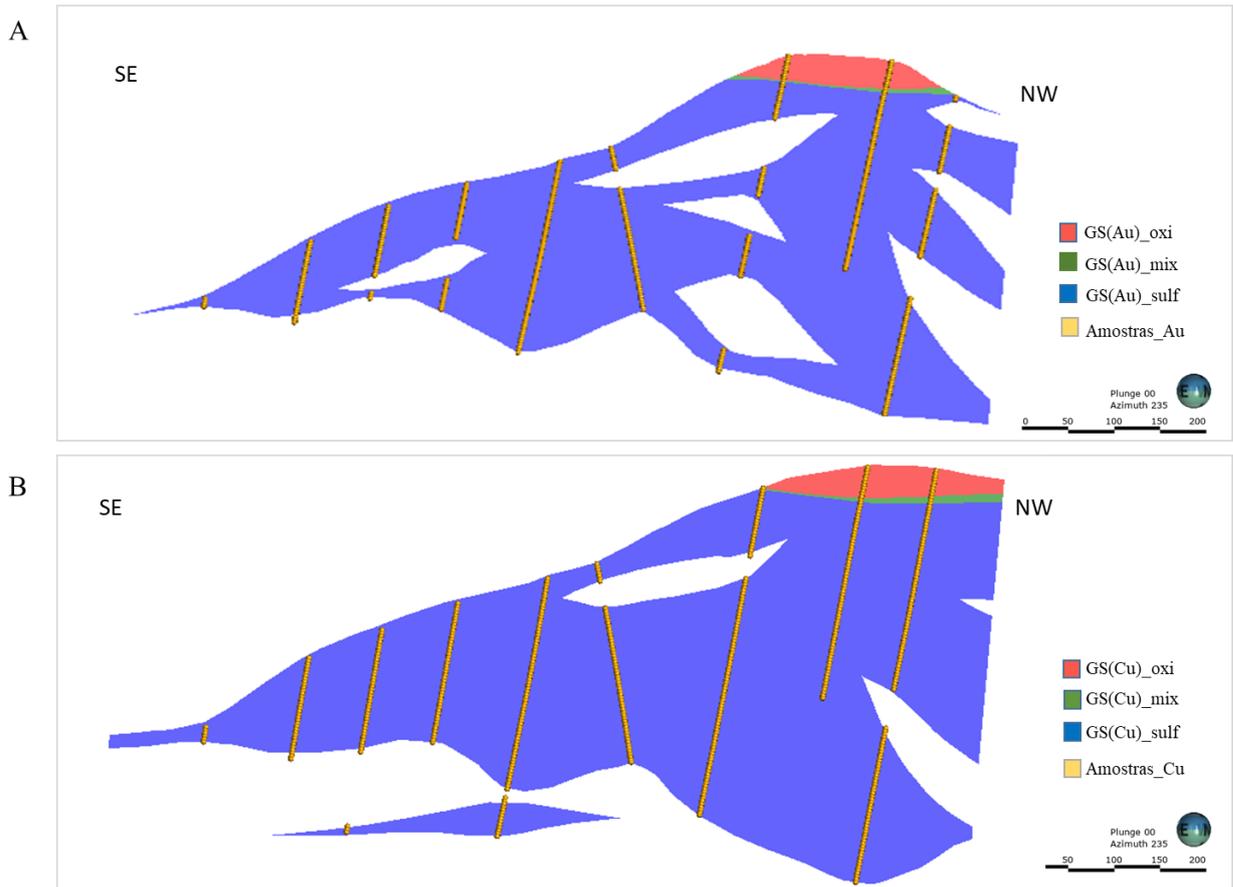
Fonte: Autor.

A área de estudo considerada para o Au (ppm) tem extensão aproximada de 3.04 km e para o Cu (%) a extensão aproximada é de 3.36 km na direção SW-NE. Foram considerados no estudo 476 furos para a variável Cu e 451 furos para a variável Au.

4.3 Análise de Domínios

O Corpo Sul da mina, área alvo desse estudo, apresenta três pacotes sobrepostos que se distinguem quanto a oxidação/sulfetação, são eles: pacote oxidado, mix e sulfetado (**figura 16**). O estado de oxidação/sulfetação indica se a rocha está em uma zona com minerais oxidados (predominantemente solos e saprólitos – pacote oxidado), em uma zona com minerais oxidados e sulfetados (predominantemente rocha intemperizada – pacote mix) ou em uma zona sulfetada (predominantemente rocha sã, com presença, entre outros, de pirita e calcopirita – pacote sulfetado). Essas características são observadas pelo geólogo em descrição de furos de sondagem e, em campo, no mapeamento geológico de mina.

Figura 16 – Seções verticais mostrando os domínios de oxidação existentes no corpo analisado, para as variáveis Au e Cu, a cor azul representa o domínio sulfetado, a verde o domínio mix e vermelha o domínio oxidado. A cor amarela representa as amostras de Au (A) e Cu (B) consideradas na modelagem dos *gradeshells* de cada elemento.

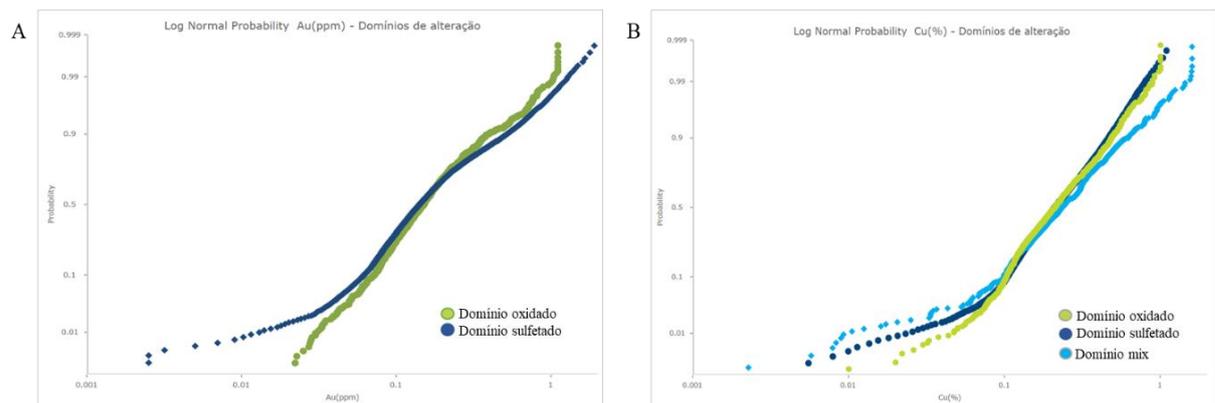


Fonte: Autora.

A planta de beneficiamento em funcionamento no complexo Chapada até o momento deste trabalho é adaptada apenas para a porção sulfetada do depósito. Dessa forma, uma análise criteriosa de domínios de oxidação/sulfetação se faz necessária anteriormente aos processos de estimativa e planejamento/sequenciamento de lavra. O pacote mix, camada de transição, que reúne características dos pacotes oxidado e sulfetado é, por vezes, o maior problema no tratamento dos dados, podendo se configurar como uma população isolada, ou fazer parte da população de minério oxidado ou sulfetado, de acordo com a distribuição dos teores e quantidade de amostras. Para esse trabalho, analisou-se os domínios de oxidação, mix e sulfetação pelo *log normal probability plot* das amostras de cada pacote, dentro dos domínios mineralizados de Au(ppm) e Cu (%).

A **figura 17** exibe o *log normal probability plot* para cada variável, considerando os pacotes de oxidação. Para a variável Au (ppm) as amostras da região do estudo se distribuíram principalmente entre os pacotes oxidado e sulfetado e pelo gráfico da figura 17 (A) observa-se que os domínios oxidado e sulfetado são populações distintas. Para o domínio Cu (%) as amostras se distribuíram entre os três pacotes de alteração. Observa-se pelo gráfico que o domínio mix é uma população distinta e, os domínios oxidado e sulfetado apresentam distribuições similares, exceto abaixo de 0.1%. Optou-se por trabalhar, ao longo desse estudo, apenas com o domínio sulfetado dentro dos *GradeShells* modificados de cada variável, que é onde concentra-se majoritariamente o recurso do depósito e é o foco da planta de beneficiamento atualmente instalada na mina.

Figura 17 – *Log Normal Probability plot* para cada variável analisada (A) Au e (B) Cu, considerando os domínios de alteração do depósito.

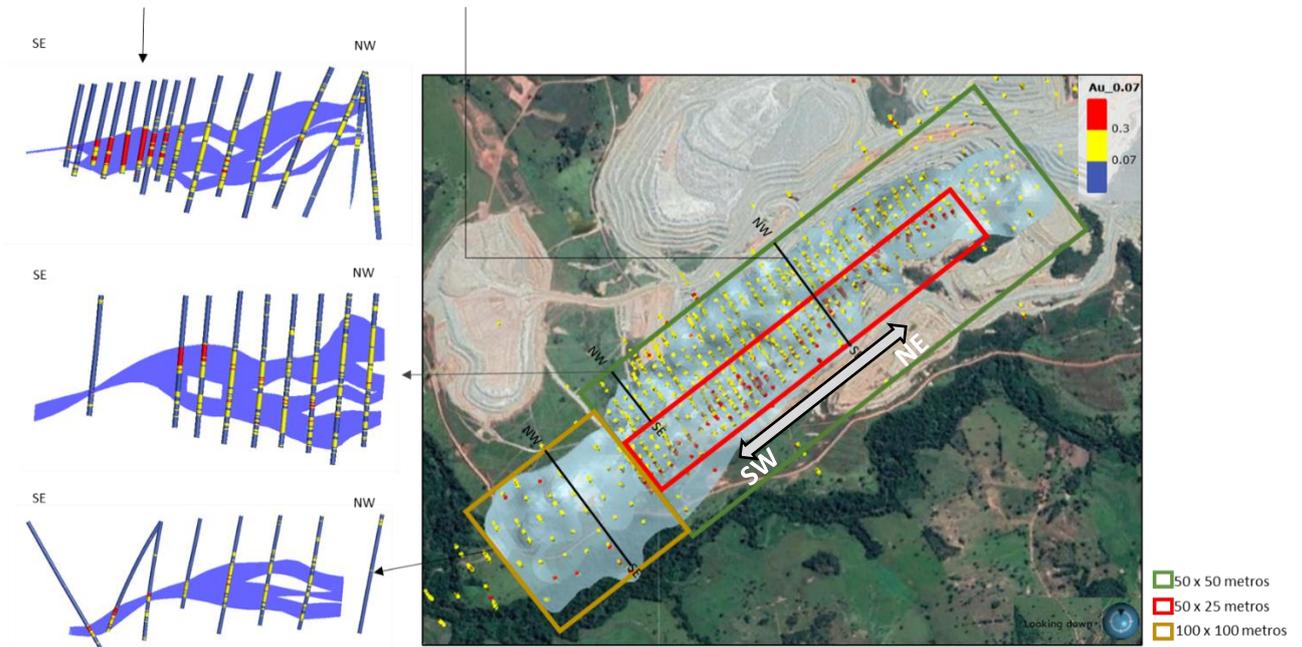


Fonte: Autora.

4.4 Malha de Sondagem

A malha de sondagem disposta na região de estudo no momento desse trabalho apresenta três tipos distintos de espaçamento amostral, de padrão geral regular. Predomina-se a malha de 50x50 m entre furos, considerando seções longitudinais e transversais. Um adensamento preferencial de 50x25 m ocorre na região de mais alto teor. E, na porção mais sudoeste do corpo, os furos estão espaçados preferencialmente na malha de 100x100 metros. A **figura 18** apresenta a divisão da área de estudos quanto ao padrão de espaçamento amostral, exemplificando em cada caso com uma seção transversal SE-NW típica que corta o corpo mineralizado. A imagem exemplifica o padrão de amostragem para a variável Au(ppm), porém o mesmo padrão é considerado para a variável Cu (%).

Figura 18 - Divisão da área de estudos quanto ao padrão de espaçamento amostral.



Fonte: Autora.

No depósito de Chapada, observa-se uma maior variabilidade de teores de Au e Cu ao longo da direção SE-NW, direção de continuidade intermediária (strike) do depósito se comparada à direção principal do plunge, SW-NE. Observa-se também, por vezes uma maior complexidade litológica/estrutural ao longo do strike, podendo haver dobras e falhas em menor escala.

4.5 Análise Exploratória e Tratamento Estatístico dos Dados

Os dados referentes às variáveis Au (ppm) e Cu (%) foram previamente tratados com a aplicação do *capping* para restrição da influência de valores extremos e, também, desagrupados, para redistribuição do peso sobre amostras preferencialmente agrupadas nas áreas de mais alto teor. O procedimento de *capping* foi realizado previamente no software Vulcan® e o procedimento de desagrupamento foi realizado no software Isatis®, pelo método de células móveis.

A **tabela 1** mostra o sumário estatístico para as variáveis Au (ppm) e Cu (%) originais, com *capping* e com *capping* e desagrupadas. As **figuras 19 e 20** exibem os histogramas de ambas as variáveis dos dados tratados. Para o procedimento de *capping*, após a composição dos dados, foi utilizada uma combinação de sete métodos para as variáveis Au e Cu para a identificação de extremos e determinação dos limites de *capping* por domínio: *probability plot*,

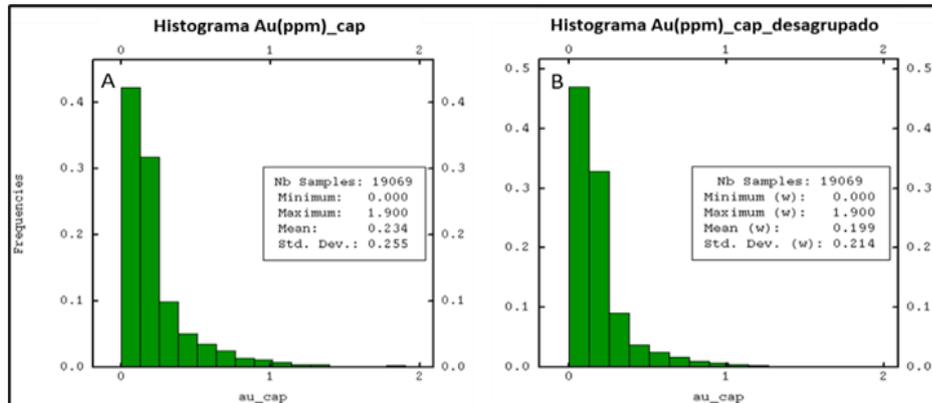
probability plot com declusterização, erro relativo, método de *Parrish*, Coeficiente de Correlação e *Metal at Risk*. O objetivo dessa etapa foi selecionar valores de corte que tenham respaldo em mais de um método. O método de *capping* por *probability plot* consiste em definir como valores extremos aqueles a partir de onde o gráfico de teor por probabilidade acumulada perde continuidade e começa a apresentar valores mais espaçados. O método *probability plot* com declusterização segue o mesmo princípio, porém utilizando dados declusterizados. O método de *capping* baseado no erro relativo mede a relação entre os dados de teor (subtração entre dois valores e divisão dessa medida absoluta por um dos valores) e são definidos como valores extremos aqueles a partir de onde o gráfico começa a ter subidas e descidas abruptas, pela perda de correlação entre os dados. O método de *capping* pela análise do coeficiente de correlação considera a dispersão dos teores ao longo de uma linha hipotética de 45° e valores muito deslocados podem ser considerados extremos. No método de *Parrish*, o teor de corte é selecionado de tal forma que o conteúdo de metal após o limite de 99% represente menos de 10% do total do metal contido. Para a avaliação final do valor de *capping* considerou-se o valor que mais se repetiu entre os métodos como base e todos os valores superiores ao valor base (*threshold*) foram redefinidos para o mesmo valor da base. Uma análise do número de dados anômalos a ser limitada foi feita para garantir que no máximo 5% do total da população de cada domínio fosse tratado como extremo. Para a variável Au o *capping* impactou 4% de toda a população de dados, um total de 762 amostras e para a variável Cu o impacto foi em 2% da população, um total de 516 amostra. Esses valores estão localizados de forma dispersa por todo o domínio analisado e não representam um domínio geológico específico.

Tabela 1 - Sumário estatístico para as variáveis Au (ppm) e Cu (%) originais, com *capping* e com *capping* e desagrupadas.

Variável	Nro de amostras	Min	Max	Média	Mediana	Dev. Pad	Variância	CV
Au	19069	0.001	5.680	0.236	0.144	0.267	0.071	1.135
Au_cap	19069	0.001	1.900	0.234	0.144	0.255	0.065	1.089
Au_cap_declus	19069	0.001	1.900	0.199	0.132	0.214	0.046	1.073
Cu	25839	0.001	2.450	0.259	0.214	0.166	0.027	0.639
Cu_cap	25839	0.001	1.100	0.259	0.214	0.162	0.026	0.627
Cu_cap_declus	25839	0.001	1.100	0.241	0.202	0.147	0.022	0.61

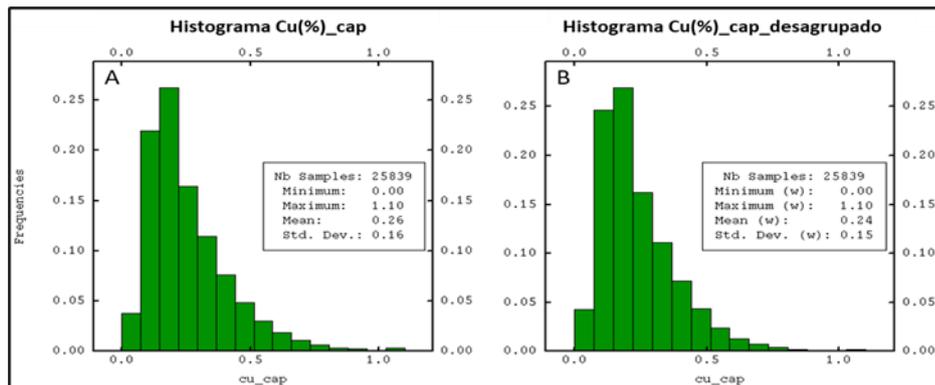
Fonte: Isatis®.

Figura 19 - Histograma para a variável Au com capping (A) e, com capping e dados desagrupados (B).



Fonte: Isatis®.

Figura 20 - Histograma para a variável Cu com capping (A) e, com capping e dados desagrupados (B).

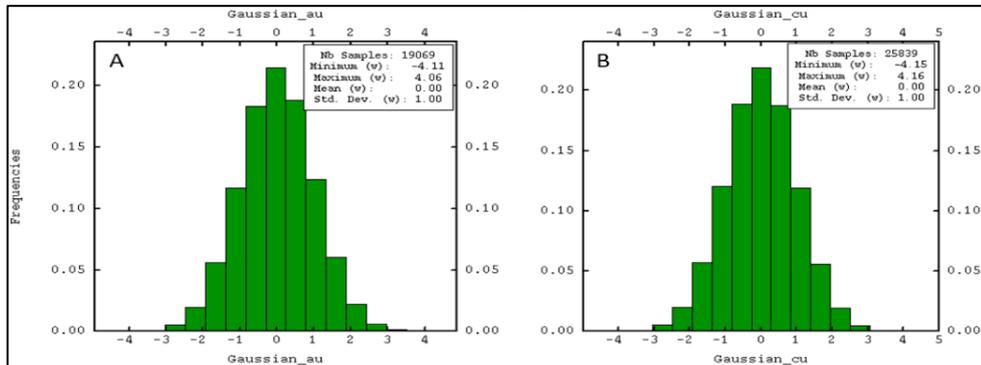


Fonte: Isatis®.

Em ambos os casos, observa-se que o *capping* e o desagrupamento reduziram a média global de teores do depósito para as variáveis analisadas, especialmente para o Au. A partir dos histogramas, nota-se que a distribuição dos teores é assimétrica positiva para o ouro, com média global de 0.199 ppm, para os dados declusterizados. O coeficiente de variação para o Au (1,075) é também mais elevado que para os dados de Cu (0,625). Para os dados de cobre, observa-se uma distribuição assimétrica positiva, porém com uma variabilidade maior entre as classes de mais baixo teor e maior média global (0.24%) para os dados declusterizados. Para este estudo foram utilizados os dados com *capping* e desagrupados. A composta utilizada nesse trabalho, para ambos os atributos analisados foi de 2 metros.

A **figura 21** mostra a distribuição no espaço gaussiano para ambas as variáveis. A distribuição dos dados foi transformada em uma distribuição normal, utilizando os pesos de desagrupamento, para uso no processo de simulação.

Figura 21 - Distribuição no espaço gaussiano para as variáveis Au (ppm) e Cu (%).

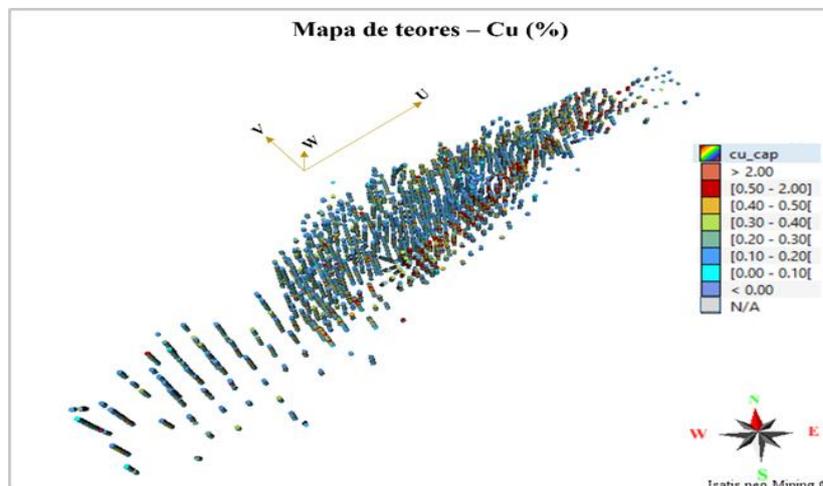


Fonte: Isatis®.

4.6 Análise Variográfica

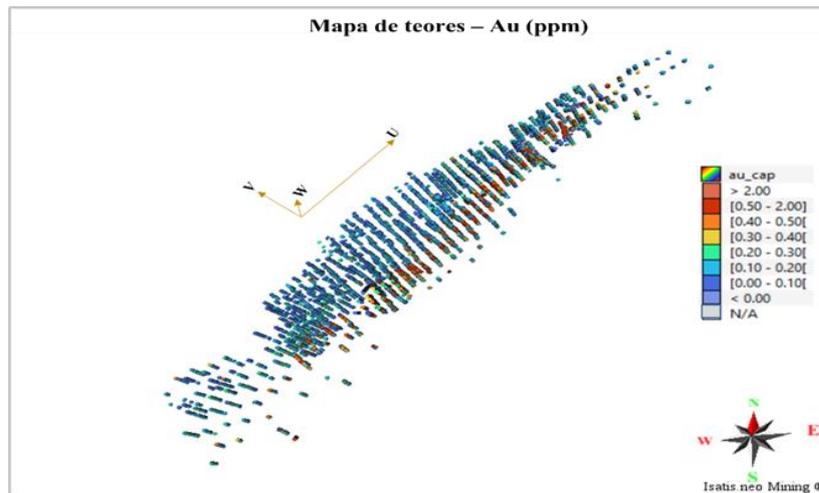
A continuidade espacial dos dados foi definida a partir de variogramas direcionais, no software Isatis®, para os dados originais e para os dados no espaço gaussiano. A **figura 22** exhibe as direções consideradas na variografia para a variável Cu, sendo a direção U a de maior continuidade dos teores, de azimuth N55°/mergulho 0° (U), direção de continuidade intermediária N144/mergulho 5° (W) e direção de menor continuidade N208/mergulho 85°(V). As mesmas direções se replicam para a variável Au, exibida na **figura 23**. A **figura 24** exhibe os variogramas no espaço real para as variáveis Au (ppm) e Cu (%) e as equações 4 e 5, descrevem a distribuição de contribuições e range para os variogramas.

Figura 22 - Banco de dados com teores de Cu (%) e as direções utilizadas na variografia do corpo.



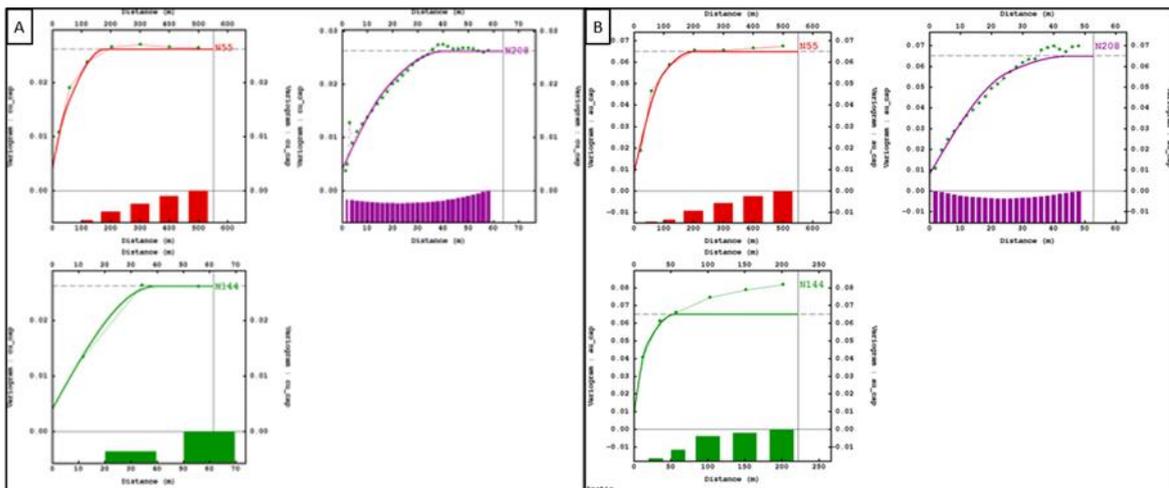
Fonte: Isatis®.

Figura 23 - Banco de dados com teores de Au (ppm) e as direções utilizadas na variografia do corpo.



Fonte: Isatis®.

Figura 24 - Variogramas no espaço real para os dados de Cu(A) e Au (B).



Fonte: Isatis®.

$$(\text{Cu}) \gamma(h) = 0.004 + [0.0042Sph \left(\frac{50}{N55} \frac{35}{N145} \frac{18}{N235} \right) + 0.018Sph \left(\frac{180}{N55} \frac{40}{N145} \frac{40}{N235} \right)] \quad (\text{Eq.4})$$

$$(\text{Au}) \gamma(h) = 0.008 + [0.025Sph \left(\frac{100}{N55} \frac{18}{N145} \frac{25}{N235} \right) + 0.032Sph \left(\frac{1200}{N55} \frac{55}{N145} \frac{45}{N235} \right)] \quad (\text{Eq.5})$$

A seguir será exibida os resultados de simulação condicional para cada uma das variáveis analisadas (Au e Cu). Diferentes padrões amostrais serão testados para análises de custo/risco sob a ótica da Classificação de Recursos, mas apenas uma das malhas (50 x 50 m) será utilizada posteriormente na análise comparativa do Máximo Erro da Estimativa (MEE)

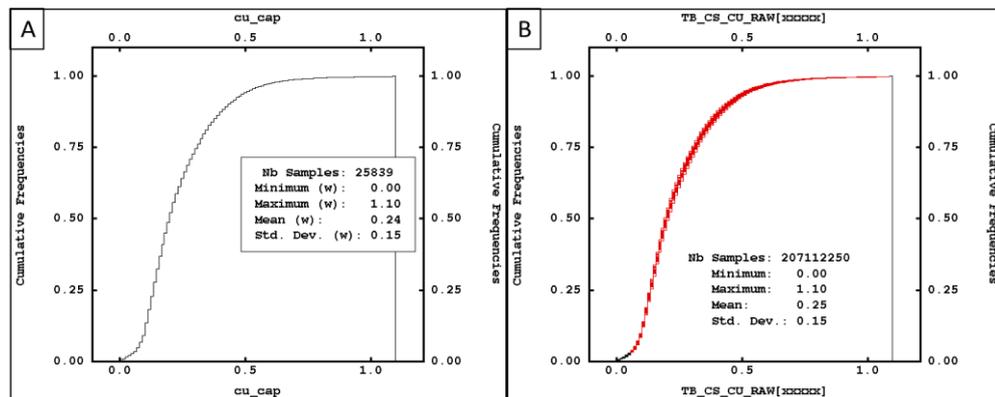
entre volumes de produção de longo prazo, deste trabalho e volumes de produção de curto prazo (trabalhos de Koppe et al. 2017 e 2019).

4.7 Simulação Condicional – Cu (%)

Utilizou-se simulação estocástica para medir a incerteza associada às duas variáveis analisadas (Au e Cu) em diferentes volumes de produção, de diferentes geometrias (considerando a mudança de suporte a simulação permite reblocar dentro dos diferentes suportes testados). A simulação foi realizada no software Isatis® utilizando o método *Turning Bands*. Essa seção exibirá os resultados de simulação obtidos para a variável Cu.

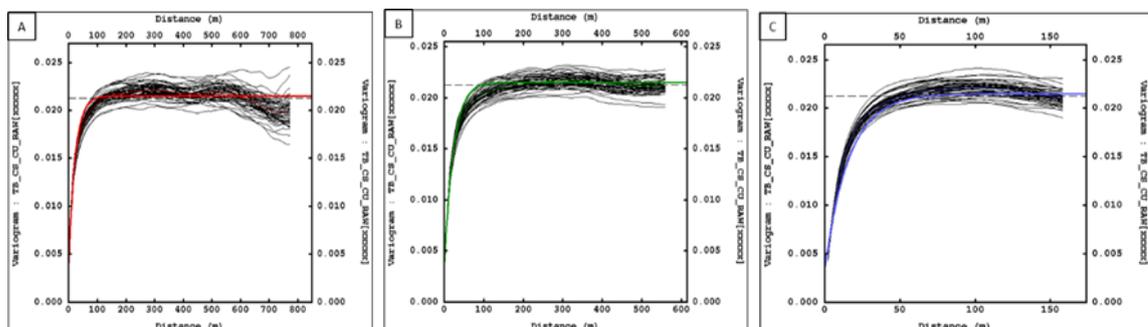
Inicialmente foram geradas 50 realizações considerando um grid de 5 x 5 x 2 m e o banco de dados original transformado para o espaço gaussiano. As **figuras 25 e 26** exibem a validação das simulações por seu variograma e histograma, respectivamente, no espaço real dos dados.

Figura 25 - Validação do histograma das simulações para a variável Cu. (A) Histograma dos dados desagrupados. (B) Histograma acumulado para os dados simulados.



Fonte: Isatis®.

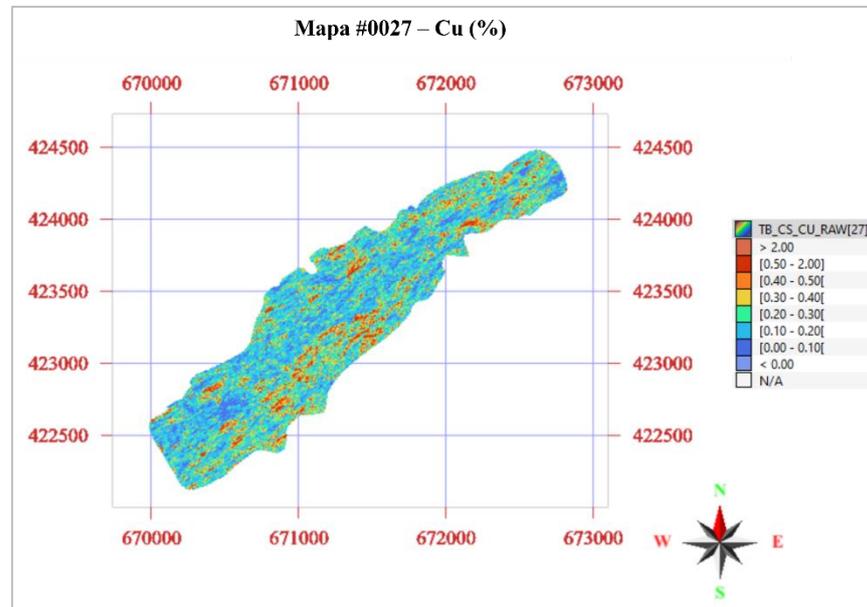
Figura 26 - Validação do variograma das simulações da variável Cu.



Fonte: Isatis®.

A partir dessas 50 simulações selecionou-se uma (realização #0027) com média e variância mais próxima dos dados originais. A **figura 27** exhibe o mapa do cenário escolhido.

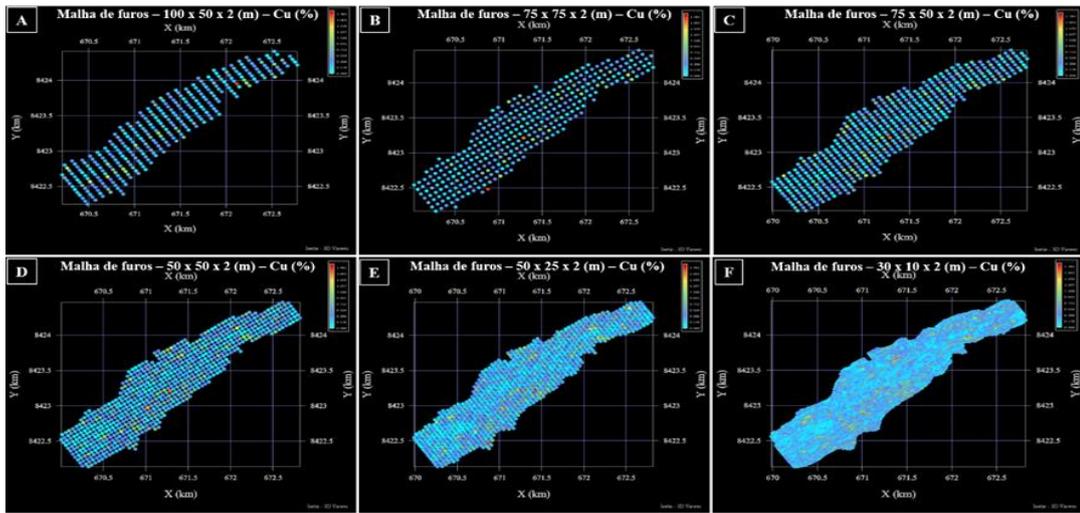
Figura 27 - Mapa do cenário de referência escolhido para a variável Cu, realização #0027.



Fonte: Isatis®.

A realização #0027 foi utilizada como cenário de referência para a variável Cu para criar diferentes grids com diferentes espaçamentos amostrais. Em cada nó do grid de referência, para cada padrão de espaçamento desejado, foi coletada uma informação no cenário de referência, e esta, foi adicionada ao banco de dados. Para a variável Cu foram geradas malhas de furos virtuais nos espaçamentos: 100 x 50 m, 75 x 75 m, 75 x 50m, 50 x 50m, 50 x 25m e 30 x 10m. A **figura 28** exhibe as malhas virtuais de cada padrão testado, evidenciando a separação entre furos. Essas malhas foram escolhidas para possibilitar a avaliação das incertezas associadas às malhas já existentes no depósito (50x50m e 50x25m), analisar a possibilidade de abertura da malha de 50x50m para 100x50m sob a óptica risco/custo dentro da classificação de recursos e dentro dessa mesma óptica analisar a possibilidade de adotar novos padrões de amostragem de 75x75m e/ou 75x50m para áreas a serem adicionadas no futuro. A malha 30x10m foi testada para análise da incerteza dentro de malhas mais fechadas, próximas à de curto prazo.

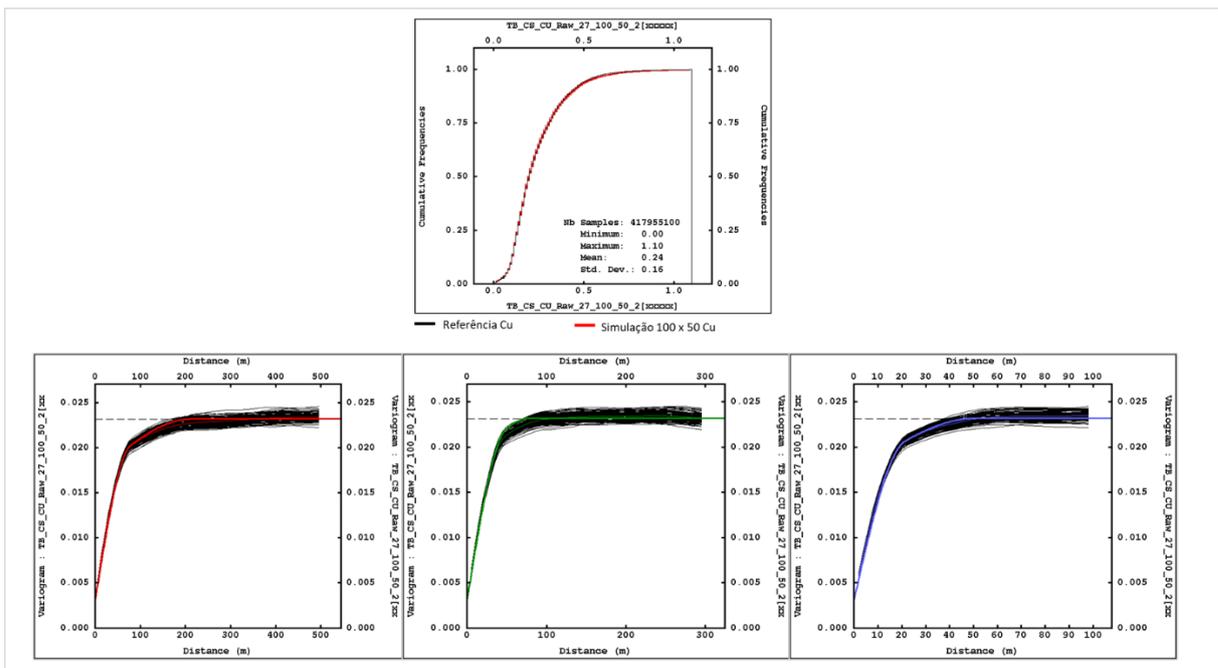
Figura 28 - Padrões de malhas de amostragem testados na análise da variável Cu. (A) 100x50m (B) 75x75m (C) 75x50m, (D) 50x50m, (E) 50x25m e (F) 30x10m.



Fonte: Isatis®.

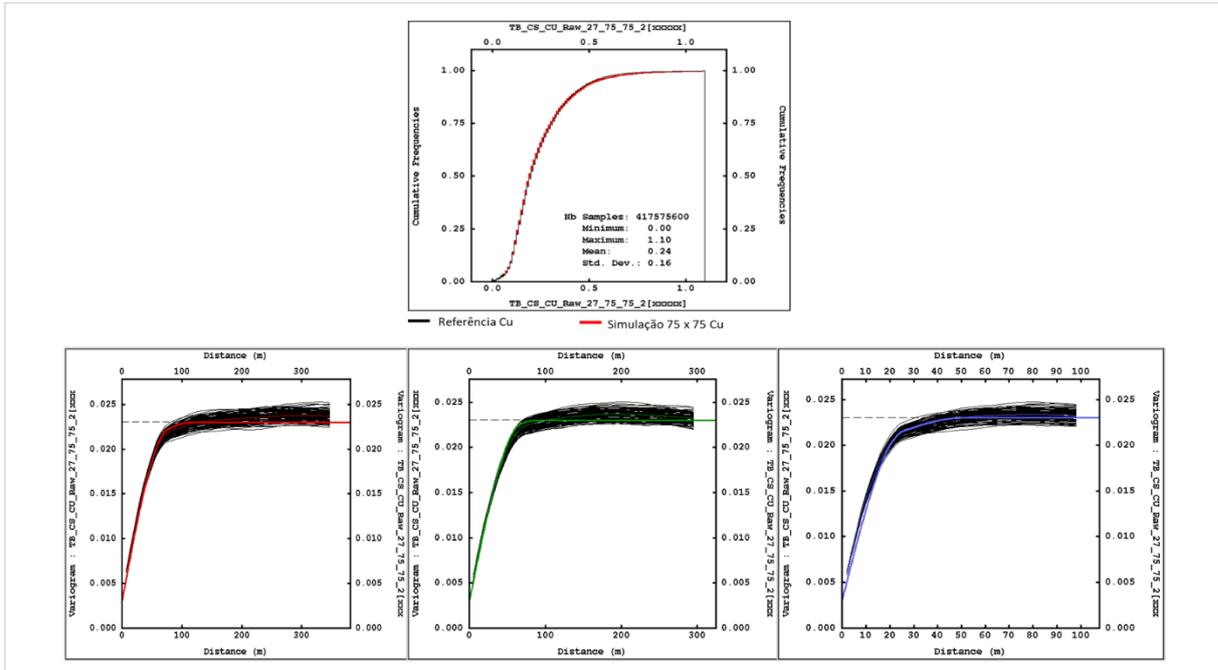
Posteriormente, foram geradas 100 realizações para cada um dos padrões de amostragem previamente criados. Também para a simulação das diferentes malhas foram utilizados grid de 5 x 5 x 2 metros. As **figuras 29 a 34** exibem os histogramas e variogramas de validação para cada uma das malhas de furos virtuais.

Figura 29 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 100x50m.



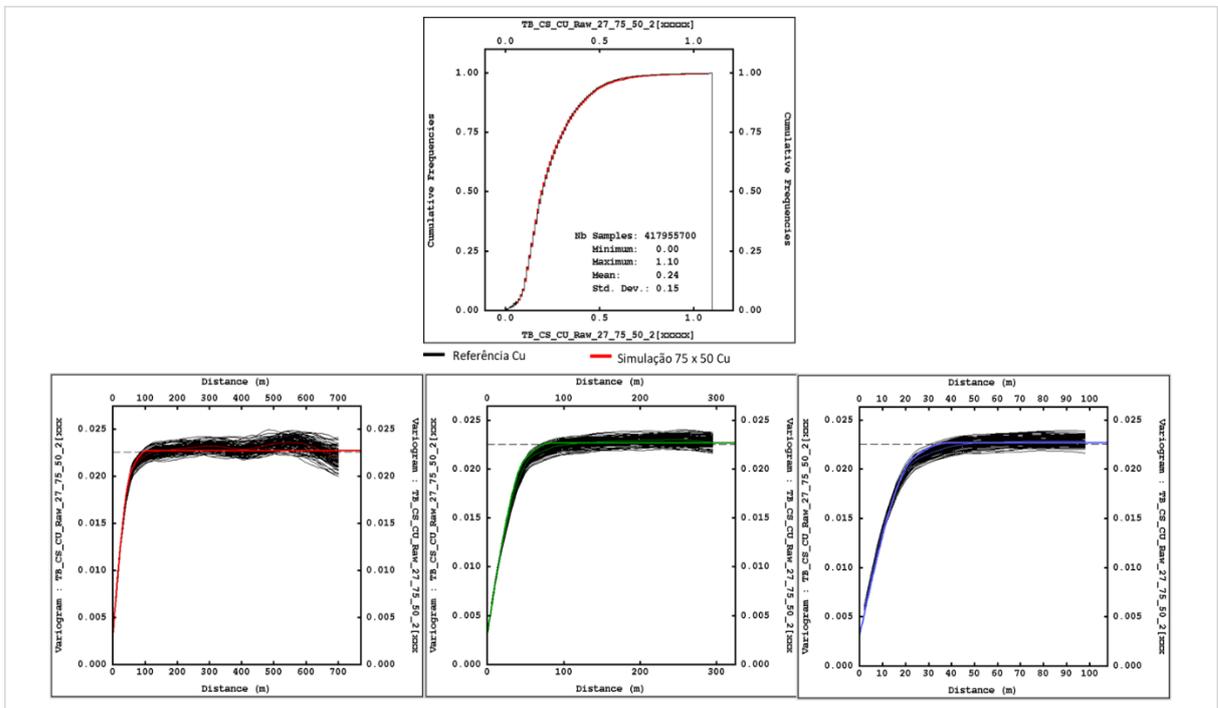
Fonte: Isatis®.

Figura 30 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 75x75m.



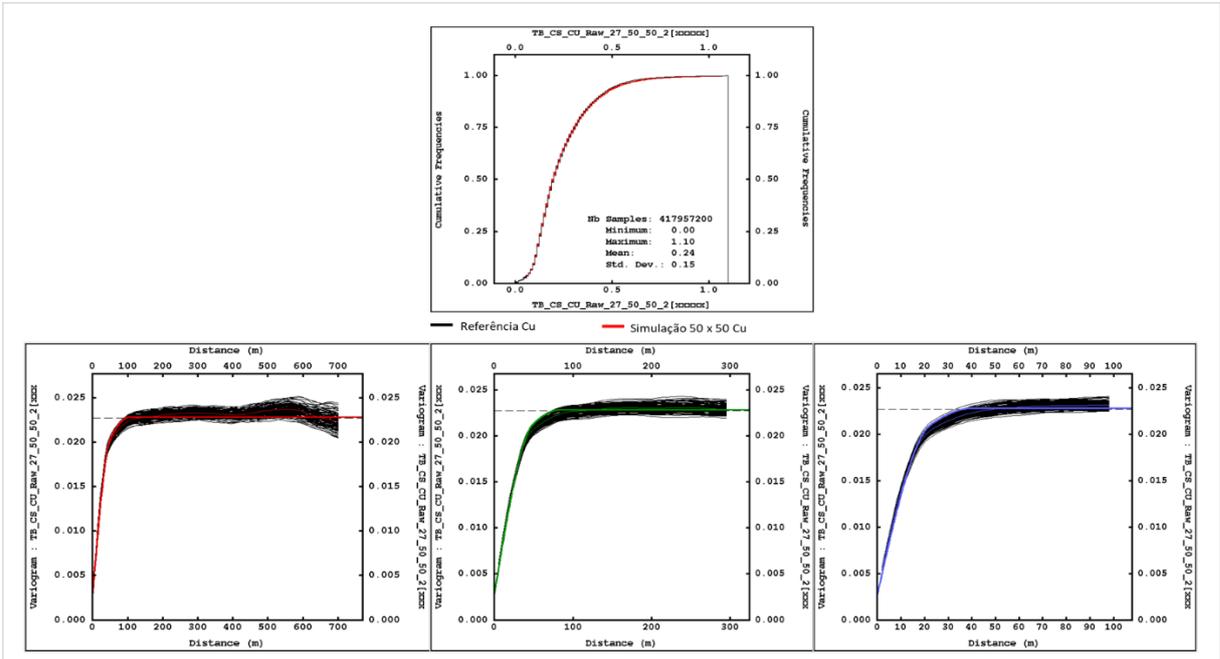
Fonte: Isatis®.

Figura 31 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 75x50m.



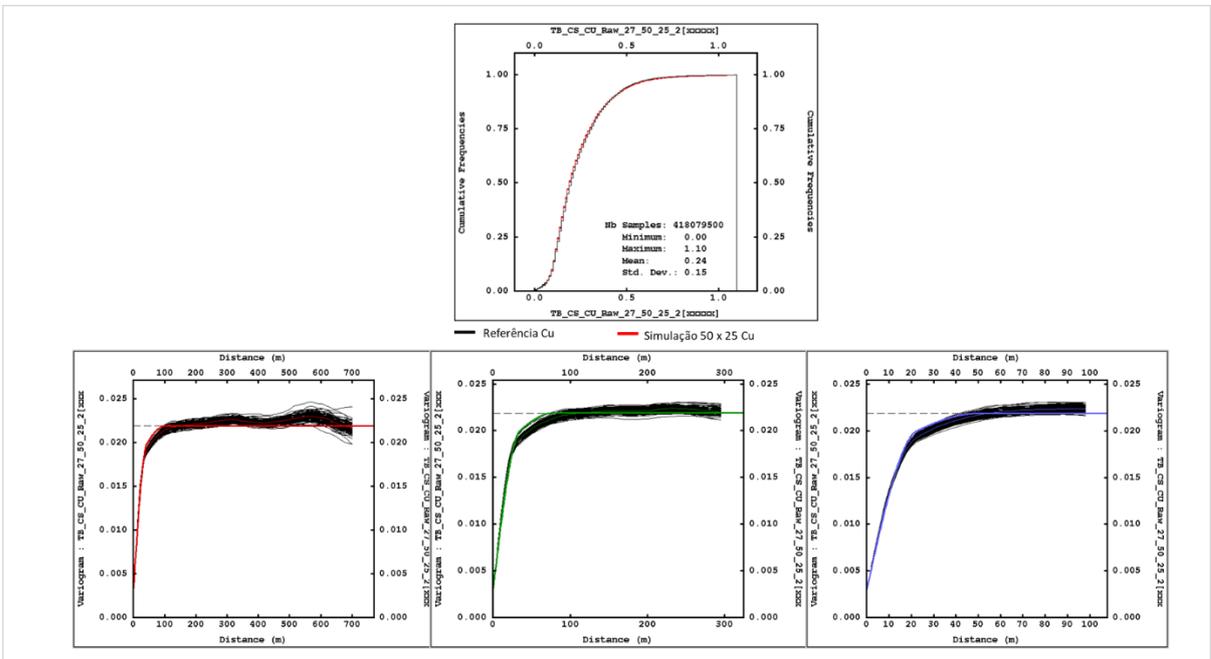
Fonte: Isatis®.

Figura 32 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 50x50m.



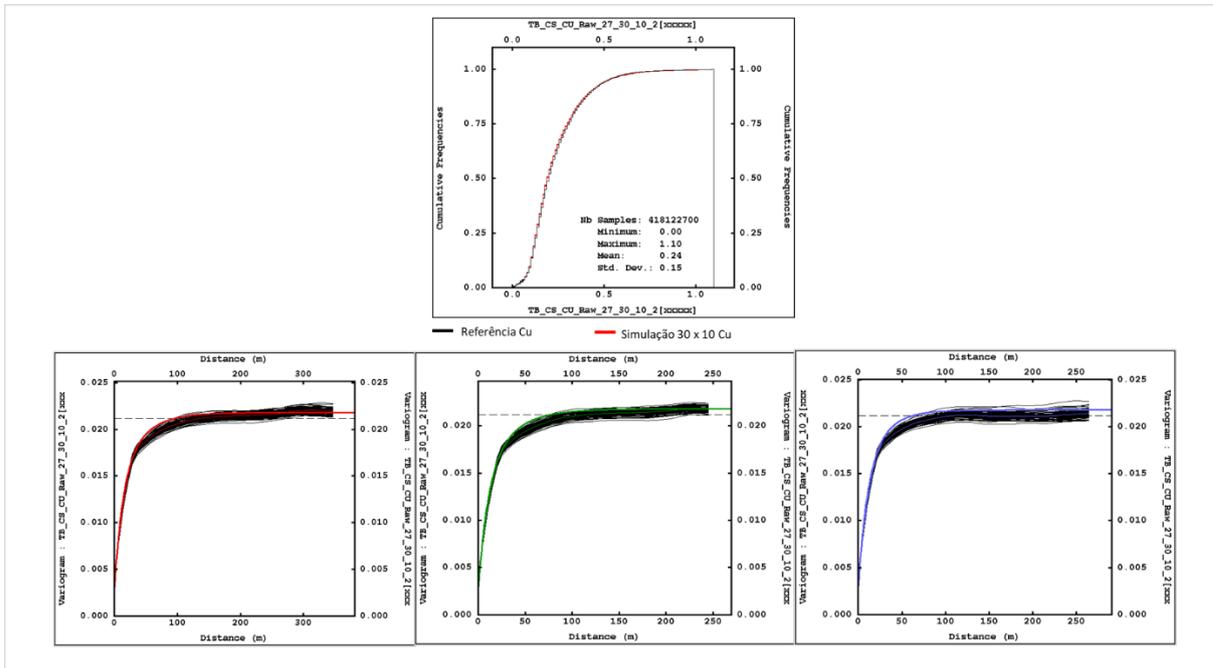
Fonte: Isatis®.

Figura 33 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 50x25m.



Fonte: Isatis®.

Figura 34 - Validação do histograma e variograma das simulações para a variável Cu no padrão de amostragem 30x10m.



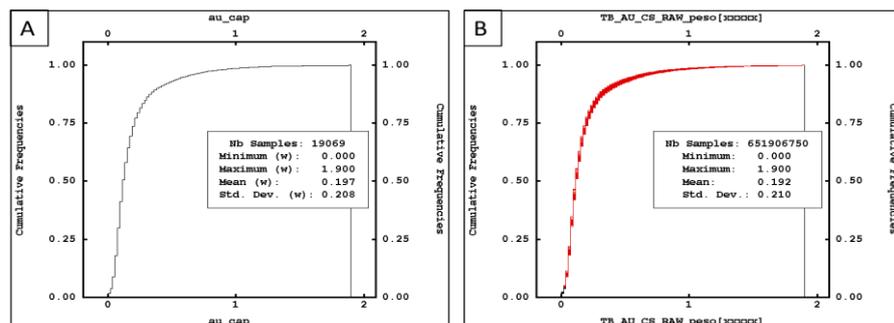
Fonte: Isatis®.

4.8 Simulação Condicional – Au (ppm)

A simulação condicional para a variável Au(ppm) também foi realizada no software Isatis® utilizando o método *Turning Bands*. O valor da composta para a variável Au também é de 2 metros.

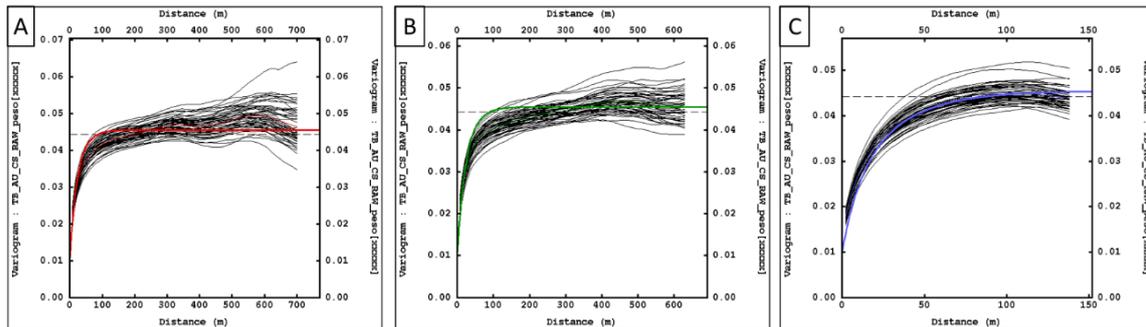
Inicialmente foram geradas 50 realizações considerando um grid de 5 x 5 x 2 metros no banco de dados original transformado para o espaço gaussiano. As **figuras 35 e 36** exibem a validação das simulações por seus variogramas e histograma, respectivamente, no espaço original. E, a partir dessas 50 simulações selecionou-se uma (realização #0016) com média e variância mais próxima dos dados originais para ser utilizada como referência (**figura 35**).

Figura 35 - Validação do histograma das simulações para a variável Au.



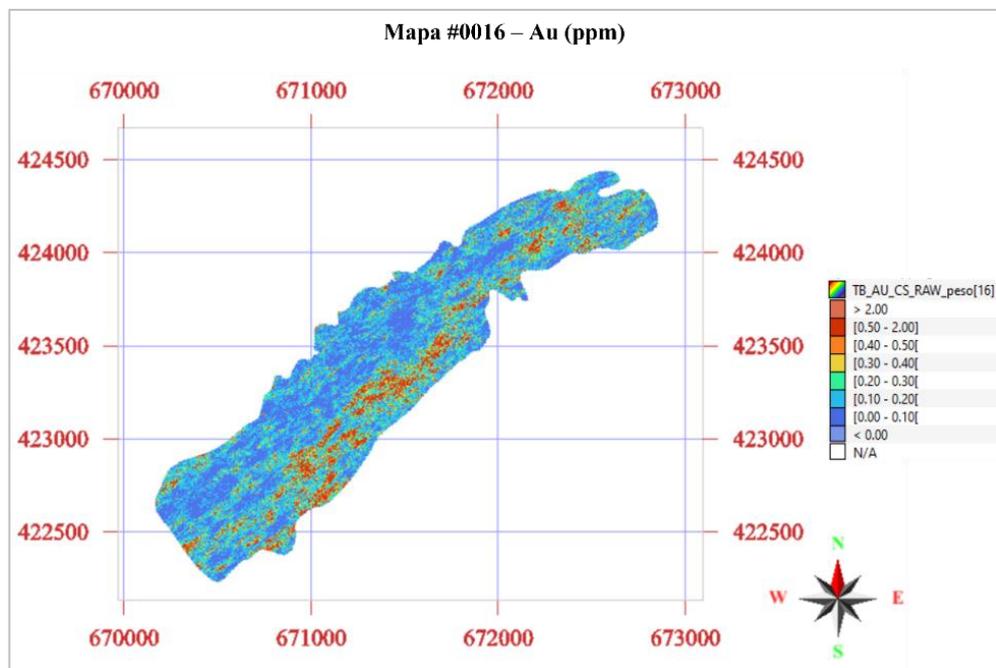
Fonte: Isatis®.

Figura 36 - Validação do variograma das simulações da variável Au.



Fonte: Isatis®.

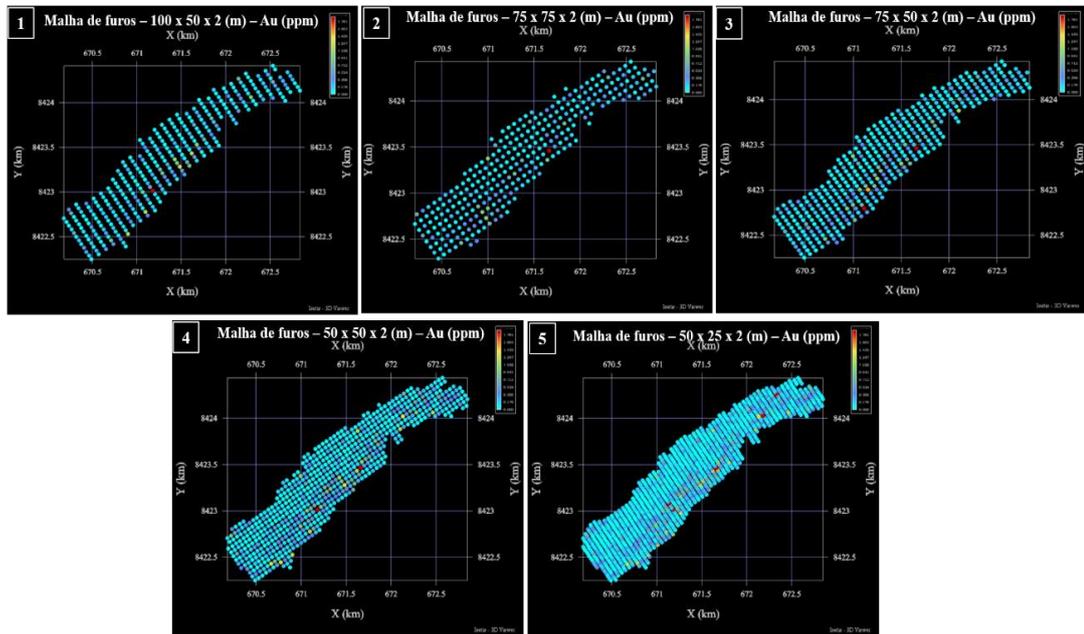
Figura 37 - Mapa do cenário de referência escolhido para a variável Au, realização #0016.



Fonte: Isatis®.

Para a variável Au foram geradas malhas de furos virtuais nos espaçamentos: 100 x 50 m, 75 x 75 m, 75 x 50m, 50 x 50m e 50 x 25m, com os mesmos objetivos citados na seção anterior para a variável Cu. A **figura 38** mostra os padrões de furos virtuais criados para cada malha. A malha 30x10 m não foi analisada para a variável Au devido ao tempo de processamento demandado e comprometimento computacional.

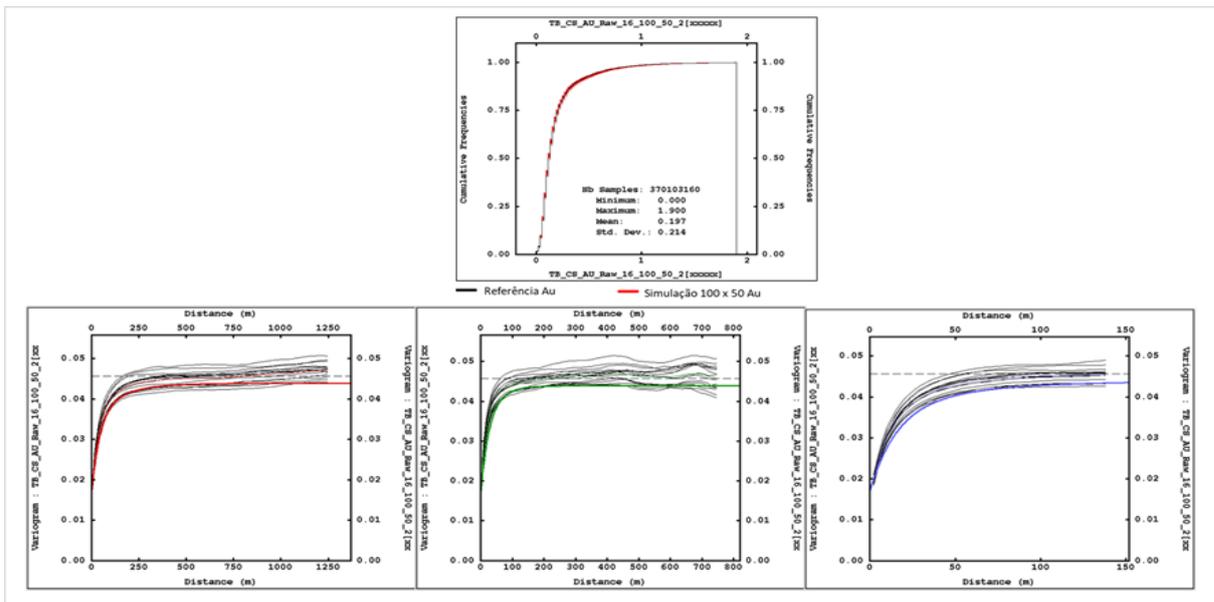
Figura 38 - Padrões de malhas de amostragem testados na análise da variável Au. (A) 100x50m (B) 75x75m (C)75x50m, (D) 50x50m e (E) 50x25m.



Fonte: Isatis®.

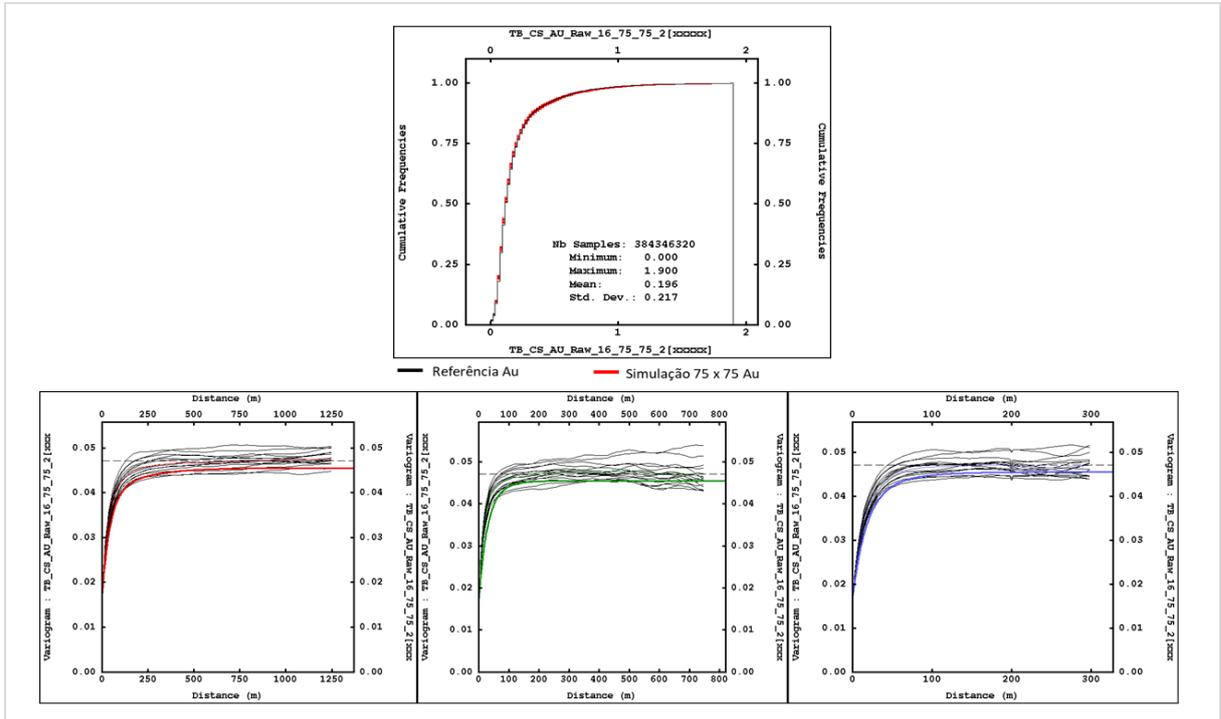
Posteriormente, foram geradas 30 realizações para cada um dos padrões de amostragem previamente criados (número reduzido por questões computacionais). Também para a simulação das diferentes malhas foram utilizados grid de 5 x 5 x 2 metros. As **figuras 39 a 43** exibem os histogramas e variogramas de validação para cada uma das malhas de furos virtuais.

Figura 39 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 100x50 metros.



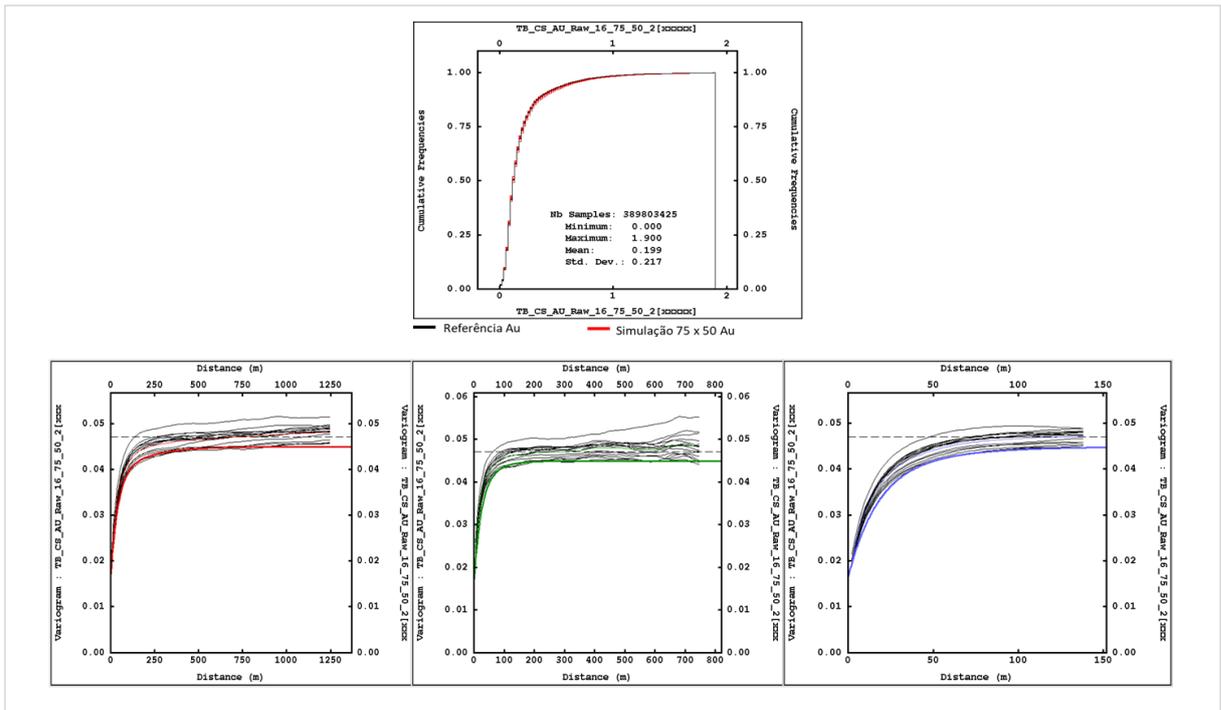
Fonte: Isatis®.

Figura 40 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 75x75 metros.



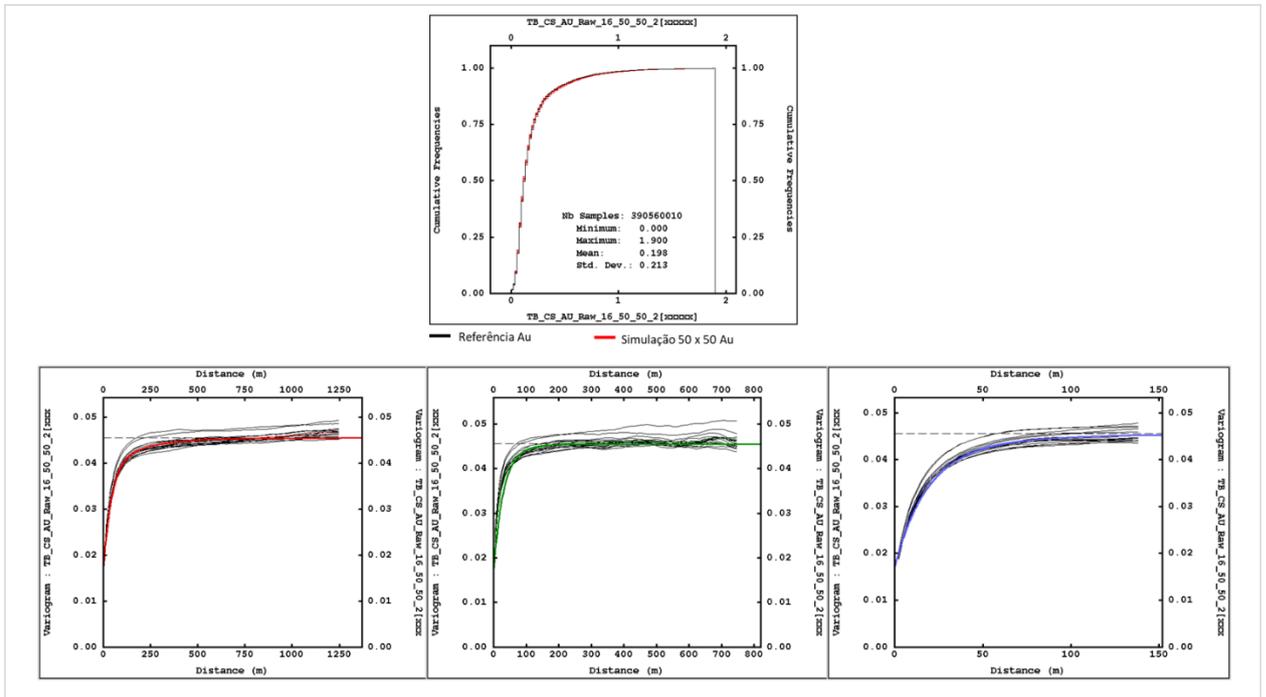
Fonte: Isatis®.

Figura 41 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 75x50 metros.



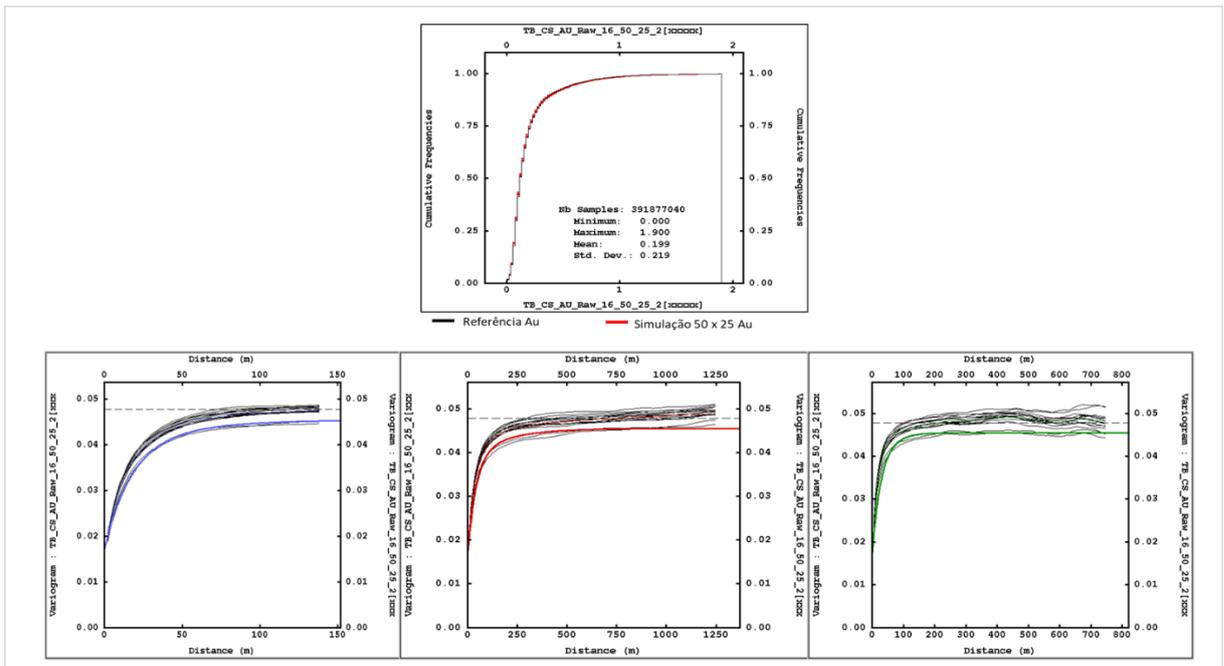
Fonte: Isatis®.

Figura 42 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 50x50 metros.



Fonte: Isatis®.

Figura 43 - Validação do histograma e variograma das simulações para a variável Au no padrão de amostragem 50x25 metros.



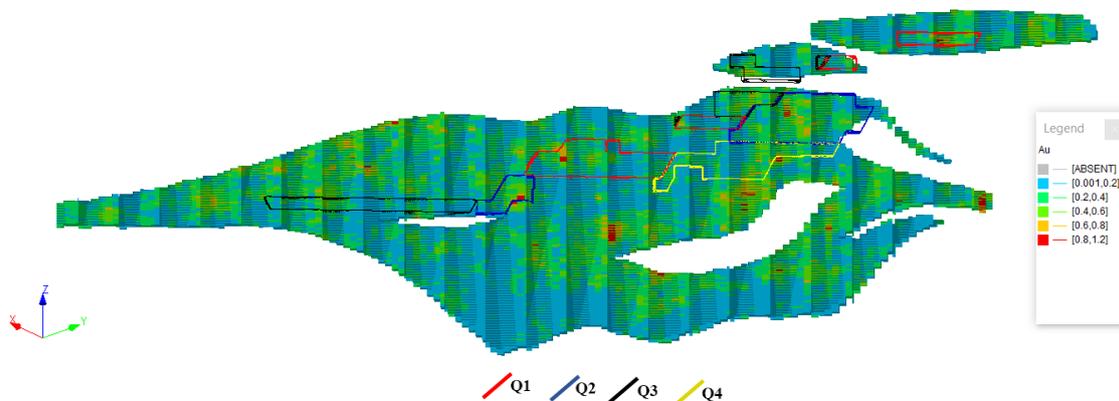
Fonte: Isatis®.

4.9 Definição dos Volumes de Produção

O máximo erro da estimativa (MEE) depende não apenas do espaçamento das amostras consideradas no processo, mas também, dos blocos de produção (volume e dimensões), da variabilidade dos dados dentro das regiões dos blocos e do modelo de continuidade de cada atributo analisado. Dessa forma, espera-se que, quanto maior o volume do bloco a ser estimado e menor o coeficiente de variação dentro do volume analisado menor seja a incerteza associado a essa estimativa.

Neste trabalho foram realizados dois estudos: O **estudo 1** calculou o MEE para cada padrão de espaçamento amostral dentro de volumes de produção de um possível sequenciamento de lavra de longo prazo da mina, para o ano de 2021, com quatro *wireframes* planejadas, cada uma para um trimestre do ano. O Q1 representa o volume hipoteticamente lavrado entre os meses de janeiro a março, o Q2, entre os meses de abril a junho, o Q3 entre os meses de julho a setembro e o Q4 entre os meses de outubro a dezembro. Para cada trimestre foi feita a média dos teores simulados em pontos para o conjunto de realizações dentro do grid 5x5x2 metros e, considerando, a distribuição desses possíveis valores de teor médio do trimestre, o MEE foi calculado individualmente para cada um dos trimestres. A **figura 44** exibe um corte de seção vertical (NW-SE) no modelo de blocos que representa o cenário de referência da variável Au, com cada geometria considerada. As geometrias são as mesmas para ambas as variáveis, Au e Cu.

Figura 44 - Corte de seção vertical no modelo de referência da variável Au, mostrando os volumes de produção do ano de 2021.



Fonte: Autora.

A equação 6 foi utilizada para o cálculo das incertezas de cada padrão amostral analisado, dentro de cada volume de produção, para as variáveis Au e Cu, onde $Q95(i)$ e $Q5(i)$

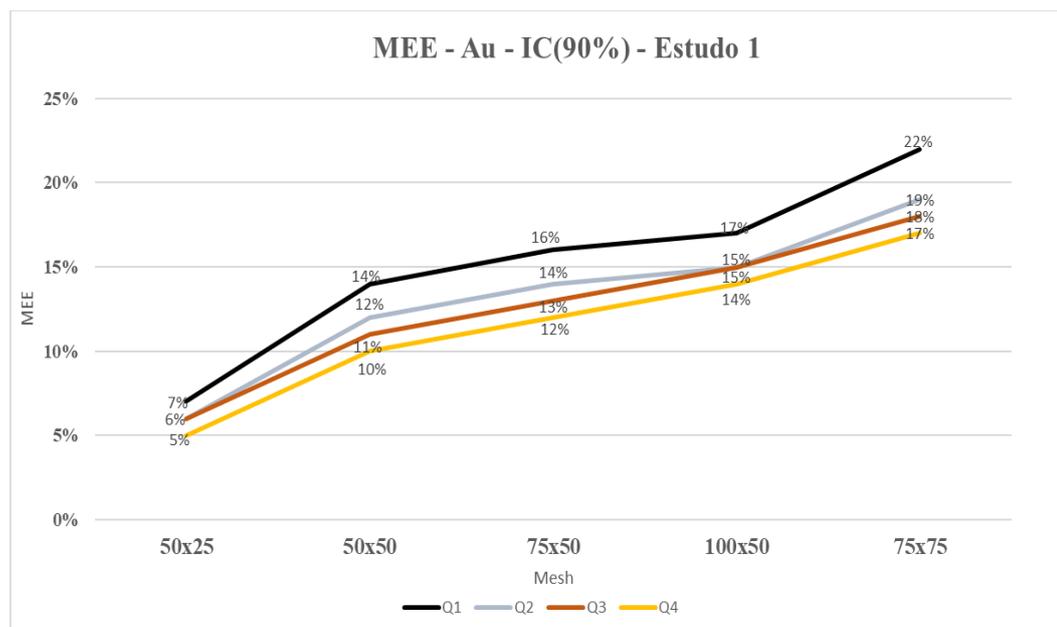
são os percentis de 95 e 5% respectivamente, dos valores simulados dentro dos volumes de produção e o $Etype(i)$ é a média dos valores simulados dentro do volume de produção i . Essa média aproxima o valor estimado para o trimestre i de um valor obtido a partir de uma interpolação por krigagem. A **tabela 2** e a **figura 45** exibem as incertezas obtidas dentro dos volumes de produção mostrados para cada trimestre do cenário considerado para o ano de 2021, para a variável Au.

$$MEE(i) = \frac{Q95(i) - Q5(i)}{2Etype(i)} \quad (\text{Eq.6})$$

Tabela 2 - Média do MEE para a variável Au dentro dos padrões de amostragem, para cada trimestre do ano de 2021.

MEE Au(ppm) - Estudo 1						
	50x25	50x50	75x50	100x50	75x75	Volume(m ³)
Q1	7%	14%	16%	17%	22%	1,050,350
Q2	6%	12%	14%	15%	19%	1,399,300
Q3	6%	11%	13%	15%	18%	1,503,850
Q4	5%	10%	12%	14%	17%	1,625,050

Figura 45 - Gráficos de MEE médio por malha para a variável Au, dentro de cada trimestre.



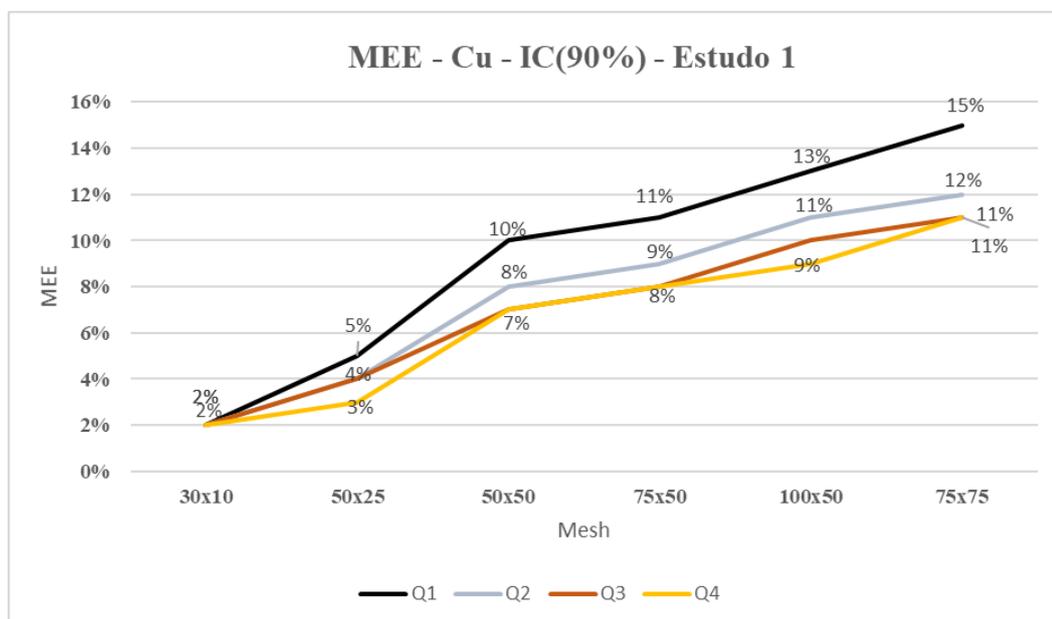
Fonte: Autora.

A **tabela 3** e a **figura 46** exibem os MEE obtidos dentro dos volumes de produção mostrados para cada trimestre do cenário considerado para o ano de 2021, para a variável Cu.

Tabela 3 – Média do MEE para a variável Cu dentro dos padrões de amostragem, para cada trimestre do ano de 2021.

MEE Cu(%) - Estudo 1							
	30x10	50x25	50x50	75x50	100x50	75x75	Volume(m ³)
Q1	2%	5%	10%	11%	13%	15%	1,050,350
Q2	2%	4%	8%	9%	11%	12%	1,399,300
Q3	2%	4%	7%	8%	10%	11%	1,503,850
Q4	2%	3%	7%	8%	9%	11%	1,625,050

Figura 46 - Gráficos de MEE médio por malha para a variável Cu, dentro de cada trimestre.



Fonte: Autora.

Observa-se pelos gráficos de MEE x espaçamento amostral dentro dos volumes de produção dos trimestres de 2021, que a malha de 75x75 metros apresentou incertezas maiores que as malhas de 100x50 metros para os mesmos volumes de produção. Isso ocorreu pelo fato do espaçamento total da malha ser de fato maior e porque ao longo do strike do corpo (direção NW-SE) a continuidade espacial dos teores é menor que na direção principal do plunge (NE-SW) e, portanto, um maior espaçamento nessa direção (75) produz uma incerteza maior que um espaçamento menor (50).

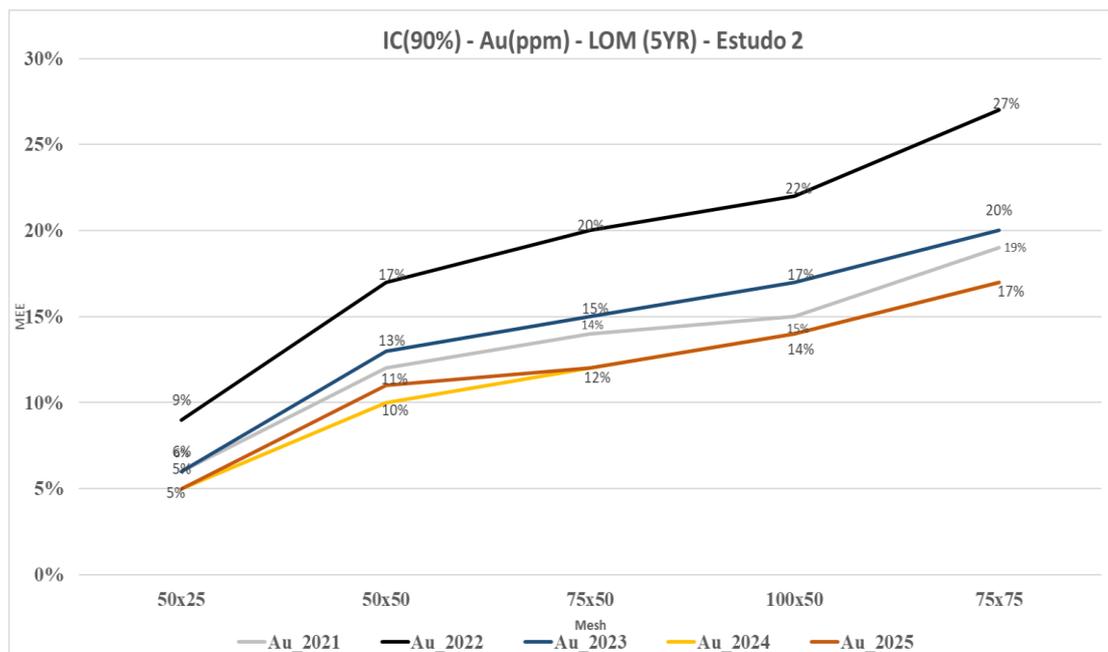
O **estudo 2** calculou o MEE dentro do volume médio representativo do trimestre para possíveis cenários reais dentro de cada um dos primeiros cinco anos do LOM (*Life of Mine*), desde o ano de 2021. Foram analisados os MEE médios do trimestre referentes aos anos de

2021, 2022, 2023, 2024 e 2025. Dessa forma obteve-se um MEE trimestral médio representativo para cada ano, até 2025. No **estudo 2** não foram utilizados os sólidos reais de sequenciamento da mina e sim criado um volume regular que representasse a média desses volumes reais de sequenciamento dos trimestres para cada ano, utilizando em z o valor da composta. A **tabela 4** e a **figura 47** exibem os MEE médios obtidos para os padrões de amostragem e volumes de produção testados para a variável Au. Observa-se que, quanto menor o volume do trimestre, maior o MEE, como esperado. Também para o estudo 2, a malha de 75x75 metros apresenta maior MEE médio que a malha de 100x50 metros, pelos mesmos motivos citados anteriormente para o estudo 1.

Tabela 4 - MEE para a variável Au dentro dos padrões de amostragem, para os 5 anos do LOM desde 2021.

MEE - Au(ppm) - 5YR LOM - Estudo 2						
	50x25	50x50	75x50	100x50	75x75	Volume (m3)
2021	6%	12%	14%	15%	19%	1,394,638
2022	9%	17%	20%	22%	27%	850,636
2023	6%	13%	15%	17%	20%	1,110,930
2024	5%	10%	12%	14%	17%	1,542,120
2025	5%	11%	12%	14%	17%	1,453,405

Figura 47 - Gráficos de MEE médio por malha para a variável Au, dentro dos cinco primeiros anos do LOM.



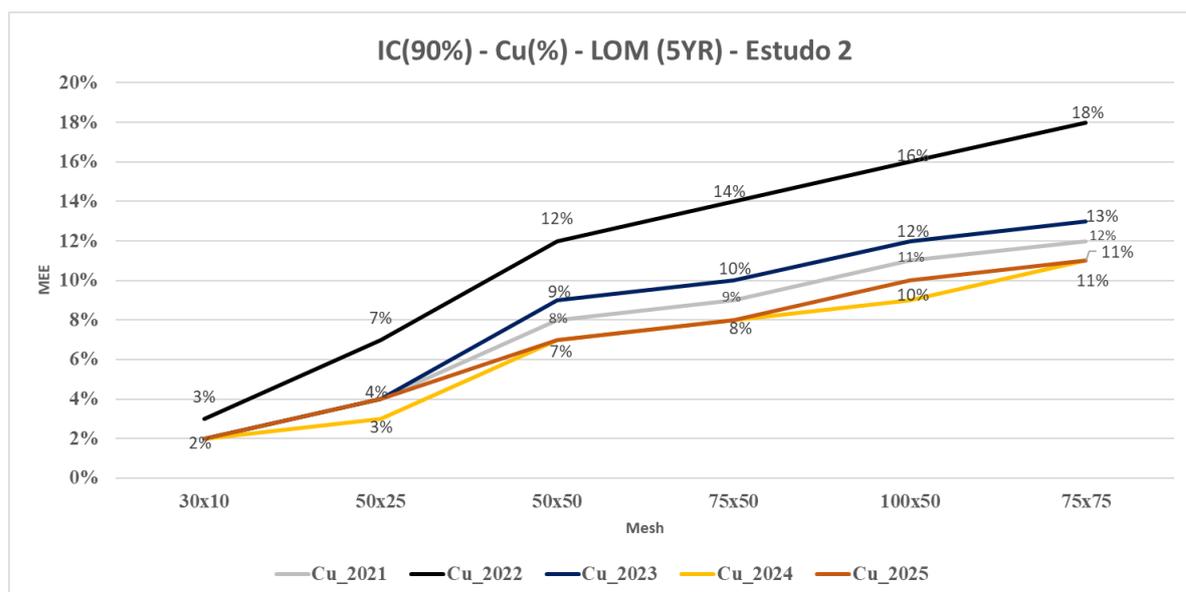
Fonte: Autora.

A **tabela 5** e a **figura 48** exibem os MEE médios obtidos para os padrões de amostragem e volumes de produção testados para a variável Cu.

Tabela 5 - MEE médios para a variável Cu dentro dos padrões de amostragem, para os cinco anos do LOM desde 2021.

MEE - Cu (%) - 5YR LOM - Estudo 2							
	30x10	50x25	50x50	75x50	100x50	75x75	Volume (m3)
2021	2%	4%	8%	9%	12%	11%	1,394,638
2022	3%	7%	12%	14%	18%	16%	850,636
2023	2%	4%	9%	10%	13%	12%	1,110,930
2024	2%	3%	7%	8%	11%	9%	1,542,120
2025	2%	4%	7%	8%	11%	10%	1,453,405

Figura 48 - Gráficos de MEE médio por malha para a variável Cu, dentro dos 5 primeiros anos do LOM.



Fonte: Autora.

Para as análises subsequentes, os estudos 1 e 2 serão considerados, o estudo 1 detalha melhor cada trimestre dentro da divisão do ano, apresentando a distribuição dos MEE médios dentro dos quatro trimestres de 2021 e o estudo 2 trabalha com uma aproximação da média de volume do trimestre para cada um dos 5 anos, de 2021 a 2025, fornecendo uma análise das incertezas esperadas nos próximos anos. O **estudo 2** trará um embasamento maior à aplicação da metodologia, uma vez que trabalhará com um conjunto maior de informações, permitirá ainda analisar a possibilidade de previsões a respeito com comportamento do MEE trimestral ao longo do ano e ao longo dos próximos anos de vida da mina e fornecerá maior confiabilidade aos resultados obtidos. Em ambos os estudos, 1 e 2, o MEE médio é calculado em relação ao

volume do trimestre, a diferença no estudo 2 é que é considerado o MEE de um volume médio que representa os quatro trimestres de cada ano analisado.

Pelos resultados de MEE médio observados nos gráficos 45, 46, 47 e 48, não se observa grande variação das incertezas apenas pela mudança da geometria dos volumes de produção, para esse depósito, dentro dos estudos 1 e 2. Especialmente se observado o ano de 2021, que é o que se repete em ambos os estudos, verifica-se que a média das incertezas nos quatro trimestres no estudo 1 é bem próxima dos MEE médios obtidos no estudo 2, também para o ano de 2021.

4.10 Definição dos Coeficientes de Variação

As **tabelas 6 e 7** exibem os coeficientes de variação calculados dividindo o desvio padrão pela média de cada variável, dentro dos volumes de produção do sequenciamento da mina, considerados nos estudos 1 e volumes médios regulares dos trimestres nos anos, considerado no estudo 2. O CV fornece a medida de variabilidade dos teores no interior dos volumes de produção analisados. Para tal utilizou-se como base de cálculo o cenário de referência de cada variável. Visto que a variação foi pequena entre os diferentes volumes de produção do trimestre, de ambos os estudos, considerou-se o CV médio para o Au de 1.06 e para o Cu de 0.56.

Tabela 6 – Coeficientes de variação para Au e Cu dentro dos volumes de produção de cada trimestre do ano de 2021.

	CV - 2021 (Por quarter)			
	Q1	Q2	Q3	Q4
Au	1.07	1.09	1.05	1.03
Cu	0.57	0.56	0.53	0.57

Tabela 7 - Coeficientes de variação para Au e Cu dentro dos volumes de produção dos primeiros cinco anos do LOM.

	CV - 2021 -2021				
	2021	2022	2023	2024	2025
Au	1.06	1.04	1.08	1.04	1.06
Cu	0.58	0.56	0.55	0.59	0.57

4.11 Análise de Incerteza - Longo Prazo x Curto Prazo

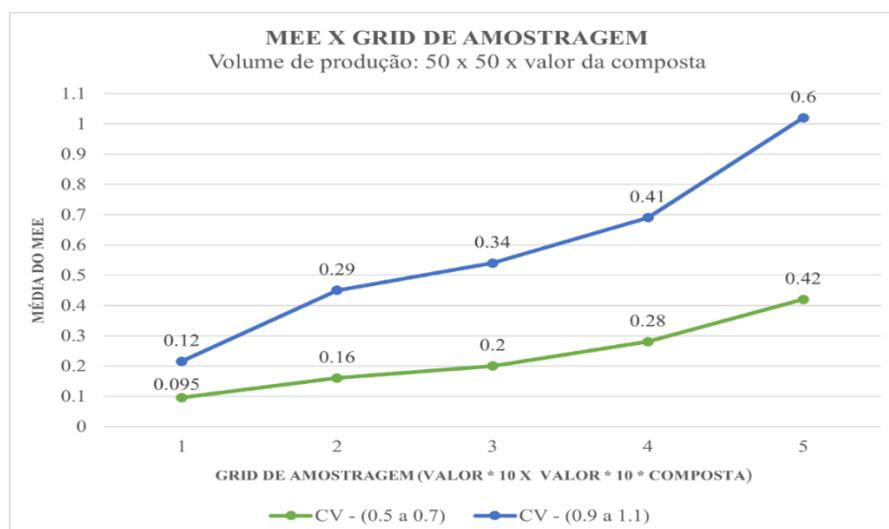
Como discutido nos artigos de Koppe *et al.* (2017) e Koppe *et al.* (2019), desenvolvidos para volumes de produção de curto prazo, o valor do MEE para os mesmos padrões de malha de amostragem, mesmos volumes de produção e dentro de um mesmo intervalo de coeficiente

de variação, mesmo para diferentes variáveis, mostra-se bastante semelhante. Nessa seção será discutida como os volumes de curto prazo e MEE correspondentes se relacionam com as incertezas de volumes maiores, de médio a longo prazo, dentro das mesmas faixas de coeficiente de variação e padrões de amostragem.

A **figura 49** exibe o gráfico de curto prazo para um volume de 5000 m³ (50x50x2m), para facilitar as discussões dessa seção, para as faixas de coeficientes de variação de 0,5 a 0,7 e 0,9 a 1,1, correspondentes aos intervalos em que se encaixam os atributos Cu e Au dessa dissertação, respectivamente. Podemos observar por esse gráfico que quanto maior o coeficiente de variação relacionado à variável, maior é o coeficiente angular do gráfico e, maior é a média do MEE. Observa-se que a incerteza é mais sensível a mudanças quando o coeficiente angular do gráfico é maior e, portanto, um adensamento amostral nesse caso representa um impacto maior na variação do MEE. Sabe-se também que, quanto maior o volume de produção, menor a média do MEE, como já visto também no capítulo 4.

Para o curto prazo os ábacos dos artigos de Koppe et. al (2019) funcionam como uma primeira ferramenta rápida e simples para selecionar-se o espaçamento amostral para diferentes tipos de depósitos, reduzindo o tempo necessário para a realização das análises de incerteza. Para o funcionamento dos ábacos de curto prazo para outras variáveis e outros depósitos, a comparação precisa ser feita dentro das mesmas faixas de CV, mesmos volumes de produção e sendo a composta vertical da amostra do mesmo tamanho do lado vertical do bloco, para o caso de furos de sondagens verticais.

Figura 49 - Gráfico mostrando a média do MEE como função do grid de amostragem para várias faixas de CV, no volume de produção de 50x50x2 metros.



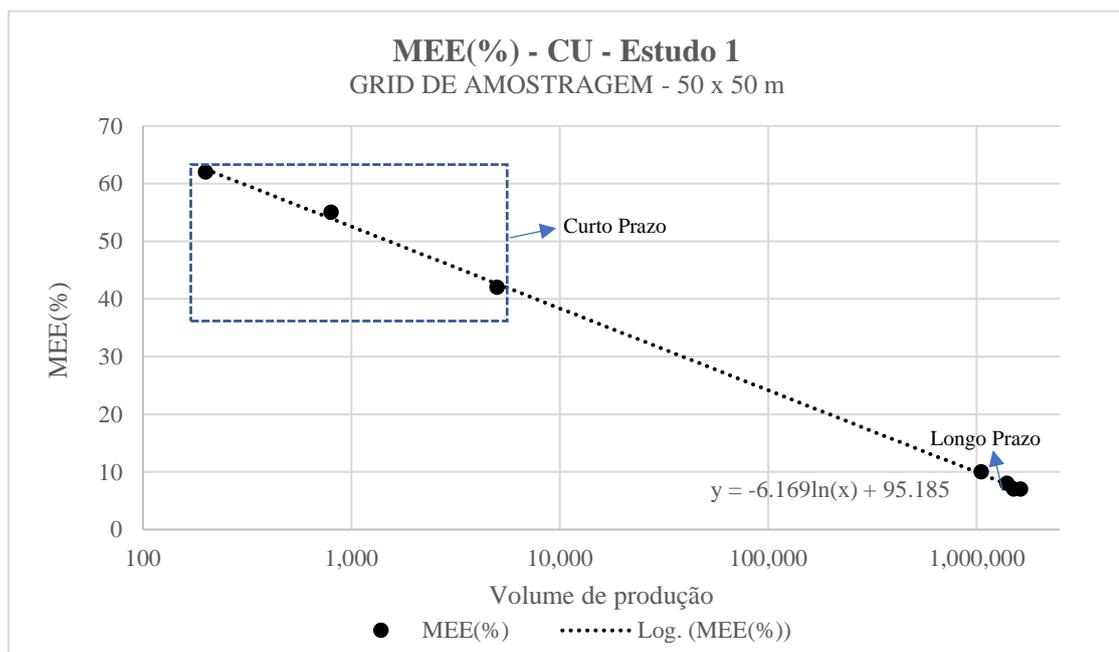
Fonte: Modificado de Koppe *et al* (2019).

Essa seção mostrará inferências sobre a correlação entre os MEEs referentes aos volumes de produção de curto prazo dos gráficos de Koppe *et al* (2019) e os MEEs obtidos nesse estudo, para volumes de produção maiores, de longo prazo. As análises foram feitas para o mesmo padrão de amostragem, que se repete entre os dois estudos, 50x50 m, e dentro das mesmas faixas de coeficiente de variação.

A relação entre volumes de curto e longo prazo foi testada a partir de funções do tipo potência, exponencial, linear e logarítmica. A função logarítmica foi a que melhor descreveu a relação de MEE entre os diferentes volumes, podendo ser usada com boa aproximação para obter-se o MEE tanto para longo quanto para curto prazo. Os resultados obtidos para as demais funções não serão exibidos nesse trabalho.

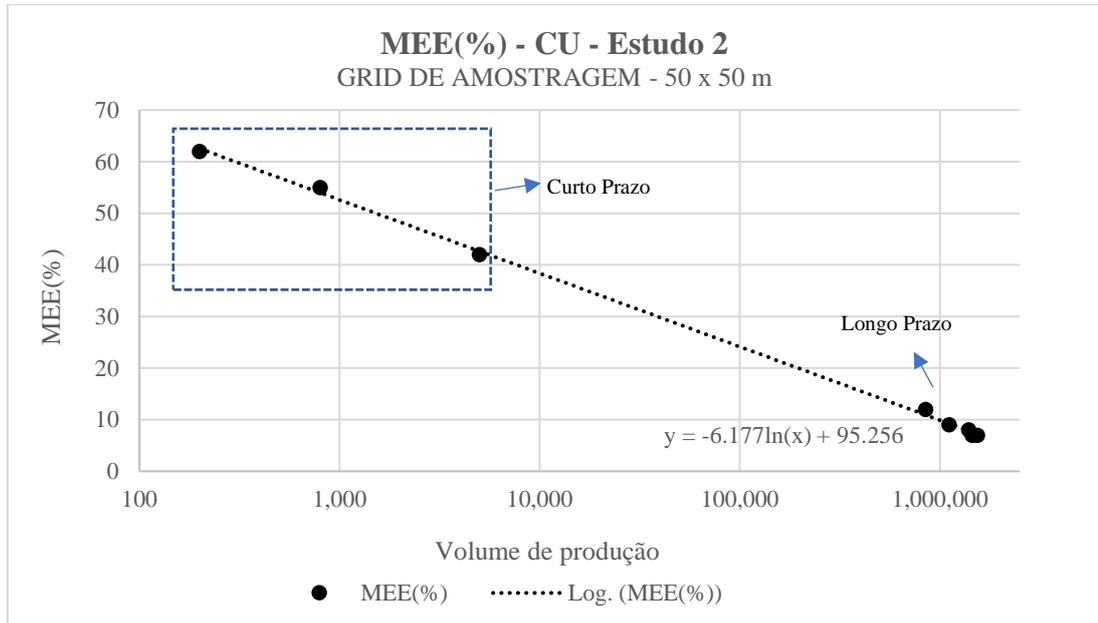
As **figuras 50 a 53** exibem os gráficos de MEE para as variáveis Cu e Au considerando os estudos 1 e 2, utilizando os volumes de longo e curto prazo dentro de uma relação logarítmica. As equações 7 e 8 exibem a relação aproximada entre o MEE e os diferentes volumes para Au e Cu, em ambos os estudos. Essas equações podem ser utilizadas para a previsão do MEE para volumes de longo e curto prazo, dentro de um padrão amostral de 50 x 50 m e uma faixa de coeficiente de variação de 0.5 a 0.7 e 0.9 a 1.1, como uma boa aproximação.

Figura 50 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Cu, no estudo 1.



Fonte: Autora.

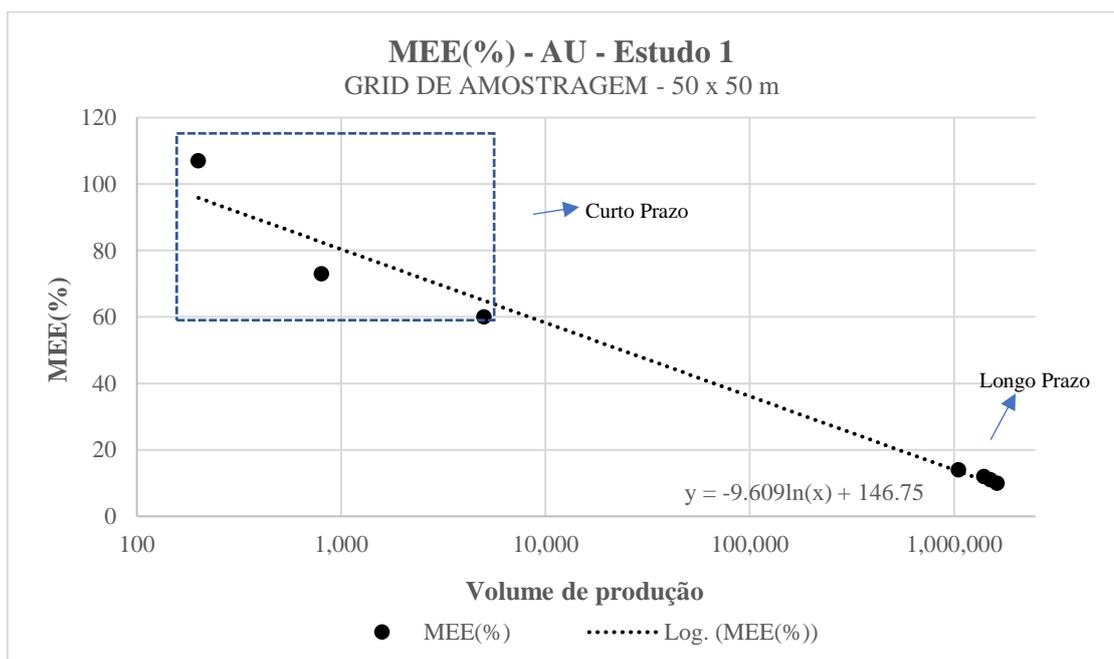
Figura 51 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Cu, no estudo 2.



Fonte: Autora.

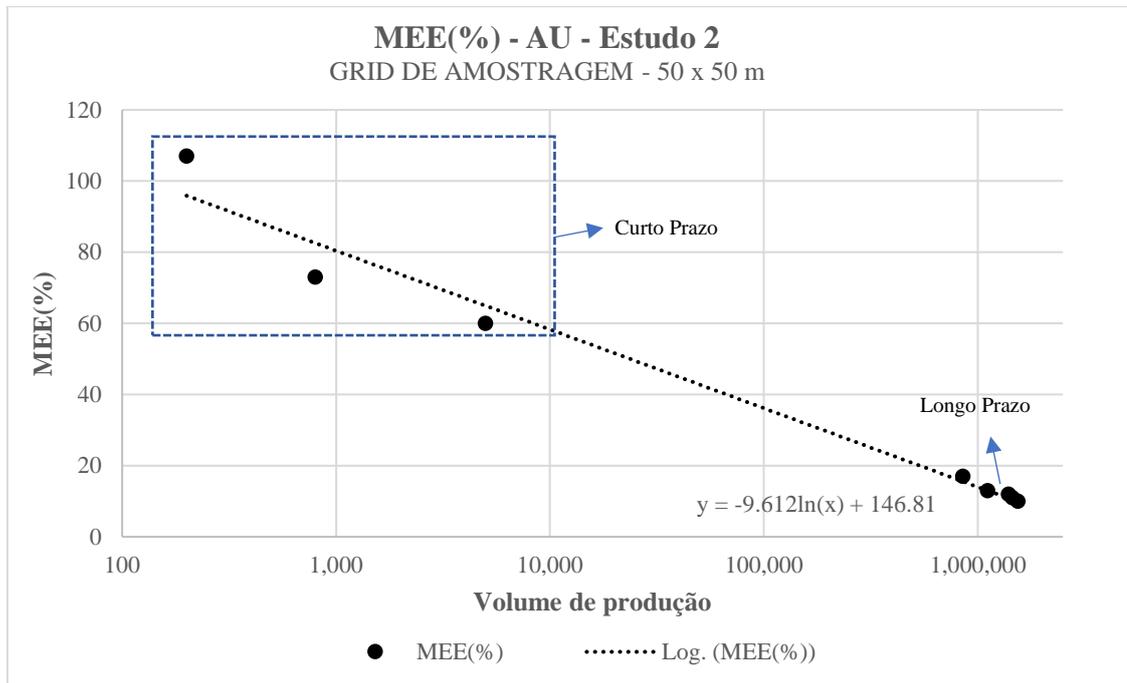
$$MEE(\%) = -6.17 \ln^*(vol. prod) + 95.2 \tag{Eq.7}$$

Figura 52 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Au, no estudo 1.



Fonte: Autora.

Figura 53 - Gráfico da relação entre a média do MEE (%) para os volumes de produção de curto e longo prazo, para a variável Au, no estudo 2.



$$MEE(\%) = -9.61 \ln^*(vol. prod) + 146.8 \quad (\text{Eq.8})$$

Alguns pontos importantes podem ser observados pelos resultados dessa seção. Para o longo prazo, dentro do estudo dessa dissertação, observou-se para ambos os estudos, 1 e 2, para ambas as variáveis, Au e Cu, que as incertezas eram muito menores para os mesmos padrões de amostragem que os observados para o curto prazo, uma vez que os volumes de produção analisados eram muito maiores. Outro ponto importante é que a relação entre volumes de longo e curto prazo descritas pelas equações 7 e 8 não se alteram variando o valor da composta, se ambas as compostas, de curto e longo prazo forem iguais. Nota-se também que as funções que relacionam a média do MEE e os volumes de produção, dentro de um mesmo padrão de malha amostral para um mesmo intervalo de CV, são bastante semelhantes para o estudo 1 e 2, analisando cada variável, Au e Cu. Ou seja, para esse depósito, considerando as geometrias de sequenciamento exatas (estudo 1) ou um volume médio representativo dessa sequência de produção (estudo 2), o comportamento do MEE é semelhante, uma vez que esses volumes estão inseridos nas mesmas faixas de CV. A partir das equações pode-se ter uma aproximação dos valores da média do MEE para diferentes volumes de produção da ordem de um milhão, dentro

das faixas de coeficiente de variação de 0.9 a 1.1 para o Au e 0.5 a 0.7 para o Cu, para a malha de 50x50m.

Por fim, os resultados obtidos a partir das **equações 7 e 8** apresentam boas respostas para volumes de longo prazo, cujo comportamento logarítmico melhor se encaixa à distribuição dos resultados de Cu e Au. A aplicação das mesmas equações para volumes de curto prazo fornece valores aproximados de MEE, porém com uma variação um pouco maior. Logo, inferências das incertezas de curto prazo a partir dos volumes de longo prazo, para mesmos padrões amostrais e mesmas caixas de CV necessitam de pelo menos um ponto do gráfico de curto prazo e ao menos uma escolha de tamanho de bloco para a malha a ser analisada.

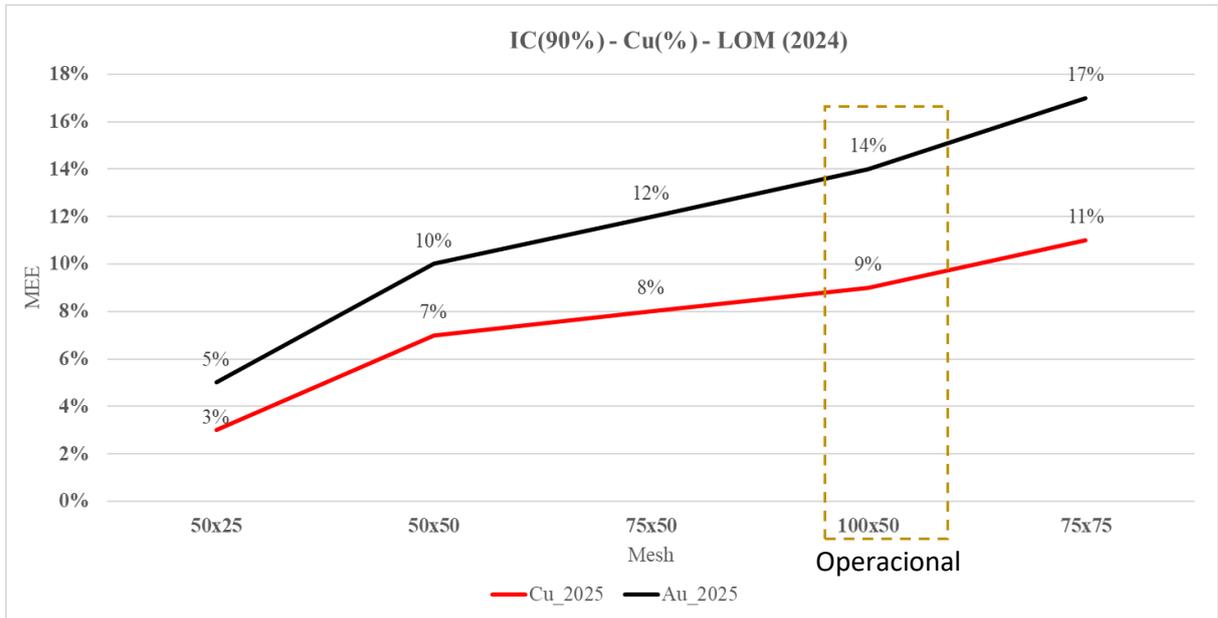
CAPÍTULO 5 - ANÁLISES DENTRO DA CLASSIFICAÇÃO DE RECURSOS

A classificação de recursos adotada no depósito desse estudo considera, de forma geral, recurso indicado aquele que apresenta a média do MEE de até 10 a 15% dentro do volume de produção anual. E, considera recurso medido aquele com a média do MEE de até 10 a 15% dentro de um volume de produção trimestral (ambos, dentro de um intervalo de confiança (IC) de 90 a 95%). Até o ano de 2021 a malha para classificação de recurso indicado majoritariamente adotada no depósito é de 100x100 metros e a malha para classificação de recurso medido é majoritariamente a de 50x50 metros. Para esse estudo serão feitas considerações apenas sobre o recurso medido, pois ambos os estudos, 1 e 2, tratam de volume de produção trimestral.

Considerando os resultados obtidos nas seções anteriores para os incertezas relacionadas aos padrões amostrais testados, dentro dos volumes de produção de longo prazo, para diferentes faixas de coeficiente de variação, podemos, podemos fazer considerações importantes sobre a utilização desse tipo de estudo para a Classificação de Recursos de um depósito e analisarmos como as equações 7 e 8, exibidas anteriormente, de correlação entre volumes de curto e longo prazo podem nos ajudar numa primeira abordagem a respeito das definição das classes de recurso de um depósito.

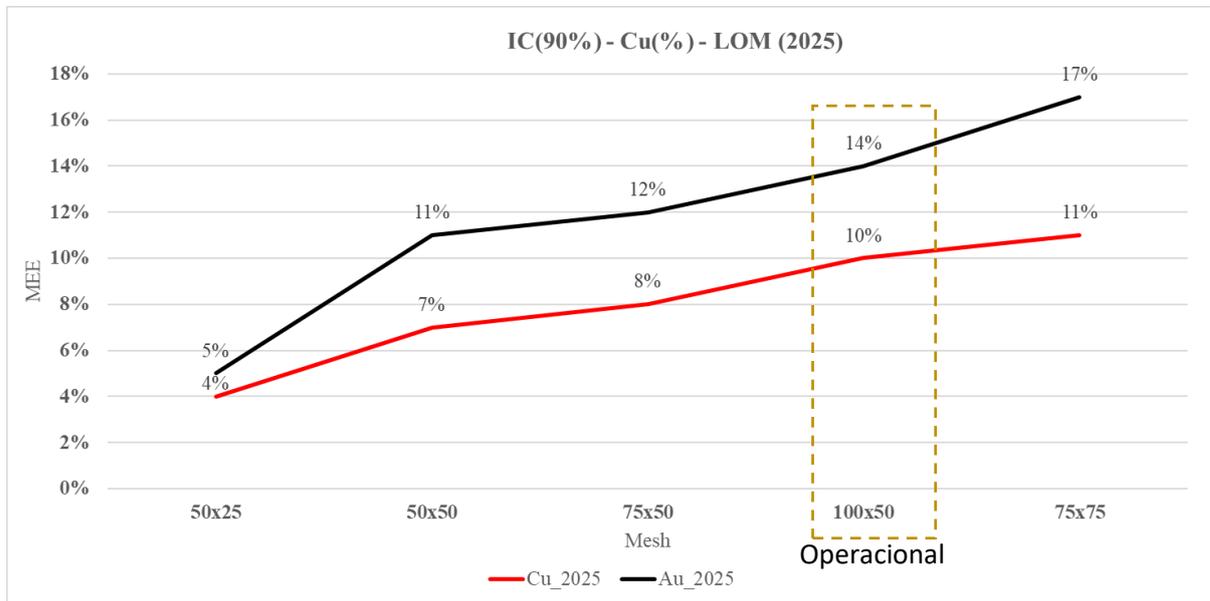
Dentro das premissas de classificação de recurso para Chapada, podemos observar que, dentro da classificação de recurso medido, para os anos de 2024 e 2025, a abertura da malha de 50x50 m para a malha de 75x50 m ou 100x50 m ainda apresentariam MEE médios entre 10 e 15% dentro de volumes de produção trimestrais, para ambas as variáveis e, portanto, poderia ser feita para a redução de custos com sondagem. Porém nas áreas já sondadas, classificadas como recurso indicado ou inferido, um adensamento só seria operacional para a malha de 100x50 m, pois já se tem disposta nessas áreas a malha de 100 x 100m. As malhas de 75x50 m poderiam ser consideradas, no futuro, para regiões de adição de recurso. Os gráficos das **figuras 56 e 57**, exibem os MEE médios para as variáveis Au e Cu nos anos de 2024 e 2025.

Figura 50 - Médias do MEE (%) para as variáveis Au e Cu, para o trimestre médio, no ano de 2024.



Fonte: Autora.

Figura 51 - Médias do MEE (%) para as variáveis Au e Cu, para o trimestre médio, no ano de 2025.

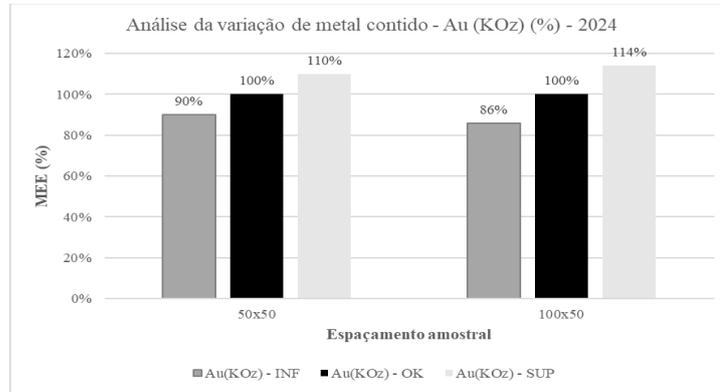


Fonte: Autora.

A partir da análise dos MEE médios dentro dos volumes de produção de longo prazo, para a classificação de recurso medido dos anos de 2024 e 2025, foi feita uma análise considerando a variação do **metal contido** para o depósito em questão, para as variáveis Au

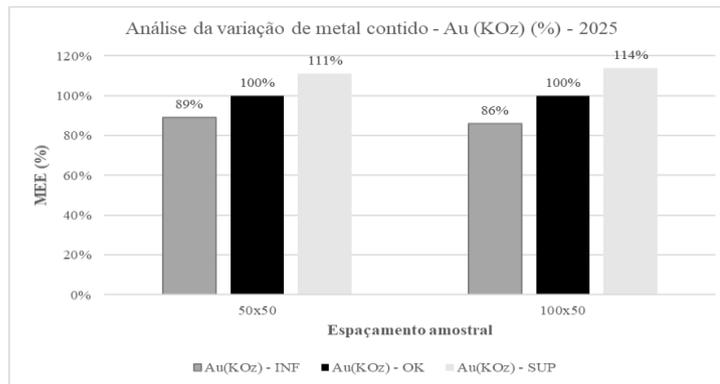
(ppm) e Cu (%), para as malhas de 50x50m e 100x50m. Os gráficos das **figuras 56, 57, 58 e 59** apresentam a variação em termos de % dos valores de metal contido.

Figura 52 - Análise da variação em % de metal contido para a variável Au no ano de 2024, para as malhas de 50x50 e 100x50 metros.



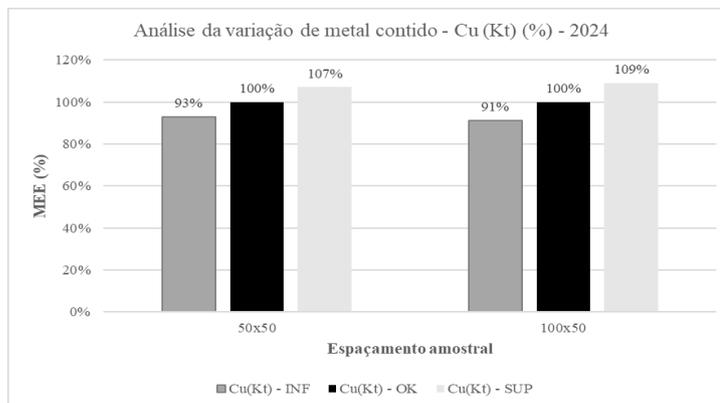
Fonte: Autora.

Figura 53 - Análise da variação em % de metal contido para a variável Au no ano de 2025, para as malhas de 50x50 e 100x50 metros.



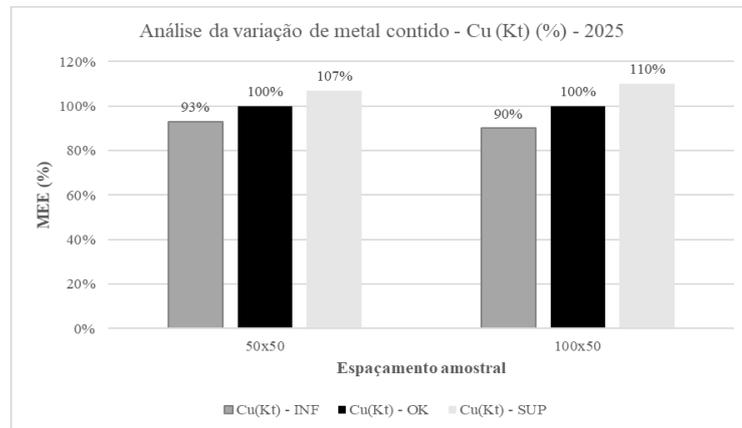
Fonte: Autora.

Figura 54 - Análise da variação em % de metal contido para a variável Cu no ano de 2024, para as malhas de 50x50 e 100x50 metros.



Fonte: Autora.

Figura 55 - Análise da variação em % de metal contido para a variável Cu no ano de 2025, para as malhas de 50x50 e 100x50 metros.



Fonte: Autora.

A partir dos gráficos acima é possível observar que, ainda que haja a possibilidade de abertura da malha de 50 x 50 metros para 100 x 50 metros para a redução dos custos em sondagem, a abertura aumenta a incerteza associada à estimativa e, portanto, a variação da quantidade de metal contido estimado passa a ser maior. A empresa precisa estar ciente dessa variação e analisar dentro dessa relação risco/custo o que mais lhe atende. Outra questão que deve ser cuidadosamente analisada é que a abertura da malha pode trazer prejuízos à compreensão geológica do corpo, especialmente para depósitos litologicamente e estruturalmente muito complexos, como o deste estudo.

Por fim, considerando as equações 7 e 8, que mostram a relação entre os gráficos de Koppe *et al* (2019) e volumes de produção maiores, entende-se que as relações estabelecidas, dentro da malha regular de 50 x 50 metros, para coeficiente de variação da faixa de 0.5 a 0.7 e 0.9 a 1.1, respectivamente podem ser consideradas para o cálculo aproximado da incerteza de outros elementos de outros depósitos dentro desse mesmo padrão de amostragem e CV e para os volumes de produção específicos que se deseja analisar variando do curto ao longo prazo na escala desse estudo. E, a partir daí, dentro das premissas de classificação de recursos de cada depósito analisado, permitiria uma análise rápida se essa malha regular específica classificaria um recurso como medido, indicado ou inferido, por exemplo.

CAPÍTULO 6 – CONSIDERAÇÕES FINAIS

O primeiro objetivo dessa dissertação consistiu em aplicar a simulação condicional para a obtenção do Máximo Erro da Estimativa (MEE) relacionado a diferentes espaçamentos de malhas de sondagem, considerando volumes de produção de longo prazo e diferentes faixas de coeficientes de variação para as duas principais variáveis do depósito de Chapada, Cu (%) e Au (ppm). Essa primeira parte do estudo utilizou o método de simulação *Turning Bands* para a geração de um conjunto de realizações para cada malha testada de cada variável com base em um cenário de referência escolhido previamente utilizando o mesmo método. Ainda nessa etapa, calculou-se os MEE separadamente em dois estudos: O **estudo 1** considerou volumes de produção dentro de um possível cenário de sólidos irregulares de sequenciamento de lavra da mina no ano de 2021 com quatro sólidos, cada um representando um trimestre do ano. E o **estudo 2** considerou a média de volume de um trimestre por ano, nos primeiros cinco anos do *Life of Mine* do depósito (2021 a 2025), utilizando para isso um sólido regular que representasse essa média de volume. Obteve-se, portanto, o MEE relacionado a cada espaçamento amostral, dentro dos conjuntos de volumes de produção de cada estudo, 1 e 2. Nessa etapa, observou-se pelas incertezas, que pouca variação existiu entre os estudos 1 e 2, podendo-se concluir que o resultado do MEE é aproximadamente igual independente da geometria do volume de produção, para um mesmo espaçamento amostral. Observou-se ainda que quanto menores os volumes, maiores as incertezas, conforme esperado e, para o depósito específico desse estudo a malha de 75 x 75 m apresentou MEEs médios bem maiores que a malha de 100 x 50 m, por ter um espaçamento global maior e porque ao longo do strike do corpo (direção NW-SE) a variabilidade dos teores é maior que na direção principal do plunge (NE-SW) e, portanto, um espaçamento nessa direção (75) produz uma incerteza maior que um espaçamento menor (50).

O segundo objetivo desse estudo propôs analisar a relação do MEE entre os volumes de produção desse trabalho e os volumes de produção de curto prazo dos trabalhos de Koppe *et al* (2019), para os atributos Cu e Au. Concluiu-se que, para ambas as variáveis, Au e Cu, os MEE relativos aos volumes de curto e longo prazo se correlacionam melhor por uma função logarítmica. Para essas análises, considerou-se os MEE relacionados à malha de amostragem comum entre os dois trabalhos, de 50 x 50 m, dentro das mesmas faixas de coeficiente de variação, 0.5 a 0.7 e 0.9 a 1.1, que correspondem respectivamente aos coeficientes de variação do Cu e Au do depósito de Chapada. A equação logarítmica descreveu muito bem as incertezas dos volumes maiores a partir de volumes de produção menores, para a variável Cu, funcionando

também para a variável Au, porém com menor sensibilidade na previsibilidade dos MEEs. Conclui-se, pois, que quando menor o coeficiente de variação do atributo analisado, ou seja, quanto menor a variabilidade de teor desse atributo, a relação entre MEE de volumes de curto e longo prazo na escala desse trabalho melhor pode ser representada por uma função logarítmica. Outra observação importante é que dentro dos estudos 1 e 2, que consideram os sólidos de sequenciamento ou um sólido regular para a representação dos volumes de produção, as funções que relacionam o MEE aos volumes foram bem semelhantes para cada variável, mostrando mais uma vez que a geometria do volume de produção exerce pouca influência sobre a incerteza. Por fim, verificou-se que a aplicação das mesmas equações para a inferência de volumes de curto prazo a partir de volumes de longo fornecem os valores aproximados de MEE, porém com uma variação um pouco maior. Logo inferências dos MEEs de curto prazo a partir dos volumes de longo prazo, para os mesmos padrões amostrais e mesmas faixas de coeficiente de variação necessitam de pelo menos um ponto do gráfico de curto prazo e ao menos uma escolha de tamanho de bloco para a malha ser analisada.

O último objetivo desse trabalho foi analisar os resultados anteriores sob a ótica da Classificação de Recursos e discutir a otimização da relação custo x risco de adensamento amostral para o depósito desse estudo. Dentro das premissas de Classificação de Recursos do depósito de Chapada, até o momento desse estudo a malha de 100 x 100 m está predominantemente associado à incerteza aceitável para a classificação de recurso indicado, dentro de um volume de produção anual e a malha de 50 x 50 m está predominantemente associada ao MEE aceitável para a classificação do recurso medido, dentro do volume de produção trimestral. Com os resultados da primeira parte desse trabalho, pode-se concluir que tanto para o Au quanto para o Cu a malha de amostragem poderia ser aberta para 75 x 50 m ou 100 x 50 m que ainda assim estaria dentro dos MEEs aceitáveis para a classificação de recurso medido, dentro do volume de produção do trimestre, para esse depósito específico. Uma abertura de malha implicaria em redução de custo de sondagem. Para esse depósito específico, pelo padrão amostral já presente dentro da área dos planos de produção até 2025, foco desse estudo, apenas a malha de 100 x 50 metros seria de fato operacional, pois o padrão regular de 100 x 100 metros já está presente em toda a área. As malhas de 75 x 50 m só poderiam ser considerados futuramente, para regiões não sondadas ou com sondagem bastante espaçada, possivelmente áreas de adição de recurso. Ainda assim, considerando a malha de 100 x 50 m, operacional, observa-se ainda pelas análises do capítulo 5 que a abertura da malha traria uma incerteza maior associada à quantidade de metal estimada, pois a incerteza de uma malha mais

aberta é maior que o de uma malha mais fechada. Dessa forma a empresa precisa avaliar se vale ou não a pena ter um risco maior quanto à quantidade de metal contido dentro dos volumes analisados para ter uma redução de custos dentro do orçamento com sondagem. Outro importante ponto a ser considerado é que a abertura da malha pode ocasionar prejuízos ao entendimento geológico do depósito. Por fim, ainda relacionado a esse objetivo e como elo final desse trabalho, temos que as equações estabelecidas no capítulo 4, que descrevem as relações entre MEE e volumes de produção maiores e menores, para um mesmo padrão amostral e mesmas faixas de coeficiente de variação, podem representar uma primeira ferramenta para a análise da incerteza dentro de volumes de produção maiores e, portanto, permitiria prever se a classificação do recuso está adequada para depósitos que adotam premissas de classificação dos recursos semelhantes ao do depósito desse trabalho ou mesmo ser um primeiro acesso para definição dessa classificação.

PROPOSTA DE TRABALHOS FUTUROS

A seguir são apresentadas sugestões para trabalhos futuros relacionados com a pesquisa realizada nessa tese:

- a. teste de outras malhas presentes nos ábacos de curto prazo e dentro de volumes de produção maiores, de longo prazo, provavelmente associados a minas subterrâneas, para melhor suporte aos resultados obtidos nessa dissertação;
- b. criação de um gráfico de fácil acesso ao MEE apenas para volumes de longo prazo, considerando diferentes padrões amostrais, regulares e irregulares com variações maiores entre os volumes, dentro de faixas específicas de CV, para auxílio prévio da classificação de recursos.
- c. realização de análises comparativas dos MEE para malhas regulares e irregulares para volumes de longo e curto prazo e como se correlacionam;
- d. análise do MEE para outros volumes de produção médios e grandes, dentro da escala desse trabalho e para outras variáveis para suporte às equações definidas no capítulo 4.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, F.F.M. de; HASUI, Y.; BRITO NEVES, B.B. de; FUCK, R.A. Províncias Estruturais Brasileiras. Atas do VIII Simpósio de Geologia do Nordeste. Campina Grande, PB. novembro, 29 p, 1977.

ARMSTRONG, M.1998. Basic Linear Geostatistics. Springer, Berlin, 153p.

BOUCHER, A., DIMITRAKOPOULOS, R., & VARGAS-GUSMÁN, J. A. (2005). Joint simulations, optimal drillhole spacing and the role of the stockpile. In Geostatistics Banff 2004 (pp. 35-44). Springer, Dordrecht.

CHILÈS, J.-P. & DELFINER, P.1999. Geostatistics: Modeling Spatial Uncertainty. Wiley-Interscience, USA, 695p.

CHILÈS, J.-P. *et al.* Modelling the geometry of geological units and its uncertainty in 3d from structural data: the potential-field method. In: Proceedings of International Symposium on Orebody Modelling and Strategic Mine Planning, Perth, Australia. [S.l.: s.n.], 2004. v. 22, p. 24.

CHILÈS, J.-P.; DELFINER, P. Geostatistics: modeling spatial uncertainty. [S.l.: s.n.], 2009. 734 p.

DEUTSCH, C. V. e JOURNEL, A. G. 1992. GSLIB: Geostatistical Software Library and User's Guide. Oxford University Press, New York, 2ª edição, 369p.

DEUTSCH, C. V. e JOURNEL, A. G. 1998. GSLIB: Geostatistical Software Library and User's Guide. Oxford University Press, New York, 2ª edição, 369p.

DOHM, C, 2005. Quantifiable mineral resource classification – A logical approach, in Geostatistics Banff 2004 (eds: O Leuangthong and C Deutsch), 1:333-342 (Springer: Dordrecht).

EMERY, X.; LANTUÉJOUL, C. Tbsim: A computer program for conditional simulation of three-dimensional gaussian random fields via the turning bands method. *Computers & Geosciences*, Elsevier, v. 32, n. 10, p. 1615–1628, 2006.

EMERY, X., HERNADÉZ, J., CORVALÁN, P., & MONTANER, D. (2008). Developing a cost-effective sampling design for forest inventory. In *Geostats 2008; Proceedings of the eighth Geostatistical Congress*.

GOOVAERTS, P. 1997. *Geostatistics for natural Resources Evaluation*. Oxford University Press, New York, 483p.

JORC, 2012. *Australasian Code for Reporting of Exploration Results, Mineral Resources and Ore Reserves (The JORC Code)* [online]. Available from: (The Joint Ore Reserves Committee of The Australasian Institute of Mining and Metallurgy, Australian Institute of Geoscientists and Minerals Council of Australia).

JOURNAL, A. G. Geostatistics for conditional simulation of ore bodies. *Economic Geology, SecG*, v. 69, n. 5, p. 673–687, 1974.

JOURNAL, A. G. & ALABERT F.G. 1988. Focusing on Spatial Connectivity of Extreme Valued Attributes: Stochastic Indicator Models of Reservoir Heterogeneities. *SPE*, No. 18324.

KOPPE V.C., 2009. Metodologia para comparar a eficiência de alternativas para a Disposição de Amostras. Tese de Doutorado. Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 181p.

KOPPE, V. C., RUBIO, R. H., & Costa, J. F. C. L. (2017). A chart for judging optimal sample spacing for ore grade estimation. *Natural Resources Research*, 26(2), 191–199.

LANTUÉJOUL, C. *Geostatistical simulation: models and algorithms*. [S.l.: s.n.], 2002. 256 p.

LI, S., DIMITRAKOPOULOS, R., SCOTT, J., & DUNN, D. (2004). Quantification of geological uncertainty and risk using stochastic simulation and applications in the coal mining industry. *Orebody Modelling and Strategic Mining Planning: The Australasian Institute of Mining and Metallurgy*, Melbourne, 233-240.

LI, S., & DIMITRAKOPOULOS, R. (2005, January). Stochastic simulation-based risk assessment for drilling optimisation. In *Application of Computers and Operations Research in the Mineral Industry-Proc. of the 32nd Int. Symposium on the Application of Computers and Operations Research in the Mineral Industry, APCOM 2005* (pp. 475-478). AA Balkema Publishers.

MATHERON, G. 1963. Principles of Geostatistics. *Economic Geology*, No.58, pp.1246-1266.

MATHERON, G. The intrinsic random functions and their applications. *Advances in applied probability*, Cambridge University Press, v. 5, n. 3, p. 439–468, 1973.

MCLENNAN, J. A. The decision of stationarity. Tese (Doutorado) — University of Alberta, 2007.

OLIVEIRA, C. G.; OLIVEIRA, F. B.; DANTAS, E. L.; FUCK, R. A. Geologia da Folha Campinorte: SD.22Z-B-I. Escala 1:100.000. CPRM – Companhia de Pesquisa de Recursos Minerais. Brasília: UnB/CPRM, 2007. (Série Programa de Geologia do Brasil – PGB), 68p.

OLIVEIRA, C. G.; OLIVEIRA, F. B.; GIUSTINA, M. E. S. D.; MARQUES, G. C.; DANTAS, E. L.; PIMENTEL, M. M.; BUHN, B. M. The Chapada Cu–Au deposit, Mara Rosa magmatic arc, Central Brazil: Constraints on the metallogenesis of a Neoproterozoic large porphyry-type deposit. *Ore Geology Reviews*, vol. 72, pg 1-21. 2015.

PILGER, G. G., COSTA, J. F. C. L., KOPPE, J. C. 2000. Projeto de Amostragem: Uma Proposição Baseada em Simulação Estocástica. *REM – Revista da Escola de Minas de Ouro Preto*, Ouro Preto, Vol. 53, No.4, pp. 256-274.

PILGER, G.G., COSTA, J. F. C. L., KOPPE, J. C. 2002. Optimizing The Value of a Sample. In: *Application of Computers and Operations Research in the Mineral Industry, 2002*, Phoenix. Proceeding of the 30th International Symposium. Littleton: Society for Mining, Metallurgy and Exploration, Inc. (SME), 2002, Vol.1, pp. 85-94.

RICHARDSON, S.V., KESLER, S.E., ESSENE, E.J. Origin, and geochemistry of the Chapada Cu-Au deposit, Goiás, Brazil: A metamorphosed wall-rock porphyry copper deposit. *Economic Geology*, 81: 1884-1898. 1986.

RICHMOND, A., WALTHO, A., BATEMAN, J., & FERGUSON, D. (2007). Locating drill holes to reduce multivariate risk. In *APCOM* (Vol. 2007, p. 33rd).

ROLO, R. M. Modelagem geológica implícita com funções de distância assinaladas 2017. 106 f. Dissertação (Mestrado em Engenharia) - Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2017.

ROSSI, M.E., CAMACHO, V.J., 2001. Applications of geostatistical conditional simulations to assess resource classification schemes. Proceedings of the 102nd annual meeting of the Canadian Institute of Mining, Metallurgy, and Petroleum (CIM), Quebec City (April 29–May 2)

ROSSI, M. E.; DEUTSCH, C. V. Mineral resource estimation. [S.l.: s.n.], 2013. 332 p.

SILVA, D.; BOISVERT, J., 2014. Mineral resource classification: a comparison of new and existing techniques. *Journal of the Southern African Institute of Mining and Metallurgy*, 114(3):265—273

SILLITOE, R.H. Porphyry copper systems. *Economic Geology Reviews*. 105, 3– 41. 2010.

SINCLAIR, W.D. Porphyry deposits. In: GOODFELLOW, W.D. *Mineral Deposits of Canada: A Synthesis of Major Deposit-Types, District Metallogeny, the Evolution of Geological Provinces, and Exploration Methods*: Geological Association of Canada, Mineral Deposits Division. Special Publication, 2007, n.5, p. 223-243.

SNOWDEN, D.V., 1996. Practical Interpretation of Resource Classification Guidelines, AusIMM Annual Conference Proceedings, Perth March 24-28, p. 305-308.

SOUZA, L.E., 2002. Estimativa de incertezas e sua aplicação na classificação de recursos minerais. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGEM), Universidade Federal do Rio Grande do Sul, 171 p

SULLIVAN, J. 2003. Determining The Value of Additional Drilling. In: Application of Computers and Operations Research In the Mineral Industry, 2003, Cape Town. Proceedings of the 31st International Symposium. South African Institute of Mining and Metallurgy, Symposium Series S31, 2003, pp. 445-452.

VALERIANO, C.M., DARDENNE, M.A., FONSECA, M.A., SIMÕES, L.S.A., SEER, H.J. A evolução tectônica da Faixa Brasília. In: V. Mantesso-Neto, A. Bartorelli, C.D.R. Carneiro, B.B. Brito Neves (eds). Geologia do Continente Sul-Americano: evolução e obra de Fernando Flávio Marques de Almeida. Beca, São Paulo, p.57. 2004.

VERLY, G., POSTOLSKY, T, and PARKER H.M., 2014, Assessing uncertainty with drillhole spacing studies: applications to mineral resources, In AusIMM: Orebody Modelling and Strategic Mine Planning 2014, Paper No. 72, 23 pp

USERO, G., S. MISK, and A. SALDANHA. "An approach for drilling pattern simulation." *Mining Goes Digital*. CRC Press, 2019. 59-66.