

Universidade Federal do Rio Grande do Sul - UFRGS
Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais

CARLOS JOSÉ EVANGELISTA SILVA

INFLUÊNCIA DO ESPAÇAMENTO DA MALHA DE SONDAGEM NA INCERTEZA DA
DECLARAÇÃO DO RECURSO MINERAL

Porto Alegre
2020

CARLOS JOSÉ EVANGELISTA SILVA

INFLUÊNCIA DO ESPAÇAMENTO DA MALHA DE SONDAGEM NA INCERTEZA DA
DECLARAÇÃO DO RECURSO MINERAL

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

Orientador: Prof. Dr. João Felipe Coimbra Leite Costa
Coorientador: Prof. Dr. Marcel Antônio Arcari Bassani

Porto Alegre
2020

CIP - Catalogação na Publicação

Silva, Carlos José Evangelista
INFLUÊNCIA DO ESPAÇAMENTO DA MALHA DE SONDAÇÃO NA
INCERTEZA DA DECLARAÇÃO DO RECURSO MINERAL / Carlos
José Evangelista Silva. -- 2020.
79 f.
Orientador: Dr. João Felipe Coimbra Leite Costa.

Coorientador: Dr. Marcel Antônio Arcari Bassani.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Escola de Engenharia, Programa de
Pós-Graduação em Engenharia de Minas, Metalúrgica e de
Materiais, Porto Alegre, BR-RS, 2020.

1. Simulação Sequencial Gaussiana. 2. Estatística.
I. Coimbra Leite Costa, Dr. João Felipe, orient. II.
Arcari Bassani, Dr. Marcel Antônio, coorient. III.
Titulo.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

CARLOS JOSÉ EVANGELISTA SILVA

INFLUÊNCIA DO ESPAÇAMENTO DA MALHA DE SONDAGEM NA INCERTEZA DA
DECLARAÇÃO DO RECURSO MINERAL

Esta dissertação foi analisada e julgada adequada para a obtenção do título de Mestre em Engenharia, área de concentração de Tecnologia Mineral, e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais da Universidade Federal do Rio Grande do Sul.

Orientador: Prof. Dr. João Felipe Coimbra Leite Costa

Coorientador: Prof. Dr. Marcel Antônio Arcari Bassani

Trabalho aprovado em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Jair Carlos Koppe - UFRGS _____

Prof. Dr. Luis Eduardo de Souza - UNIPAMPA _____

Profa. Dra. Vanessa Cerqueira Koppe - UFRGS _____

Agradecimentos

Agradeço ao Prof. Dr. João Felipe Coimbra Leite Costa, meu orientador; ao Programa de Pós-graduação de Engenharia de Minas, Metalúrgica e de Materiais da UFRGS; e ao Laboratório de Pesquisa Mineral e Planejamento Mineiro (LPM) por te me acolhido em sua equipe de alunos de pós-graduação. Essa instituição é responsável por reunir excelentes condições de desenvolvimento técnico e científico para e mim e para muitos. Agradeço ao Prof. Dr. Marcel Bassani por acompanhar os meus passos desde as disciplinas, as quais ele foi monitor, e na fase dos trabalhos da dissertação como meu Coorientador, sempre gentilmente ajudando ao bom entendimento dos diversos conteúdos cursados ao longo desse tempo.

Especialmente, sempre serei grato pela minha mãe, pois minhas conquistas vêm de uma base familiar e educacional que ela me deu ao longo da minha vida.

“Praticando e demonstrando o exemplo de bondade e respeito por todos os seres vivos, é uma poderosa contribuição para trazer paz e harmonia no Mundo”

(Gesh Kelsang Gyatso)

Resumo

Os testemunhos de sondagem são as principais informações para a modelagem geológica, e são caros e escassos. O espaçamento da malha de sondagem pode ser escolhido para reduzir as incertezas no modelo geológico e no inventário de recursos minerais. Essa dissertação investiga como a incerteza dos recursos minerais é influenciada por distintos espaçamentos das malhas de sondagem através de um estudo de caso sobre a mineralização de bauxita no platô da Amazônia brasileira. A Simulação sequencial Gaussiana (SGS) foi realizada em uma malha muito adensada e assumimos que essa simulação representa a distribuição verdadeira da variável de interesse. Após, seis bancos de dados distintos com espaçamento de dados regulares foram obtidos a partir desta simulação: (i) 25x25; (ii) 100x100; (iii) 200x200; (iv) 400x400; (v) 800x800 e (vi) 1200x1200 metros ao longo das direções X e Y, respectivamente. Então, 50 realizações usando Simulação sequencial Gaussiana (SGS) foram geradas usando cada um desses bancos de dados como dados condicionais. As realizações foram feitas em suporte pontual e redimensionadas para o volume de bloco usado na lavra. Em seguida, as curvas Teor-Tonelagem das realizações obtidas com as diferentes bases de dados foram calculadas e comparadas. As Curvas de Teor-Tonelagem resultantes foram usadas para quantificar a relação entre a amostragem da sondagem e a incerteza dos recursos minerais globais. Os resultados mostraram que a incerteza do recurso mineral diminui à medida que o espaçamento de dados diminui. Dependendo do nível de incerteza aceitável, espaçamentos de dados mais amplos podem ser selecionados. Assim, a equipe de projeto pode economizar no orçamento e no tempo das atividades de declaração de recursos. Este espaçamento adequado de sondagem pode ser definido usando um valor de incerteza aceitável. O estudo de caso ilustrado demonstra a complexidade e utilidade do fluxo de trabalho proposto.

Palavras-chaves: Geoestatística, Simulação sequencial Gaussiana, Incerteza da malha amostral.

Abstract

Rock cores from drillings are the main source of information for ore modeling which are expensive and scarce. Data spacing should be properly chosen to reduce uncertainties in the geologic model and mineral resource inventory. This study investigates how the uncertainty of the mineral resources is influenced by distinct data spacings through a case study on a bauxite mineralization in Brazilian Amazon plateau. First, Sequential Gaussian Simulation (SGS) was run in a dense grid and assumed that this simulation represents the true grade distribution. Second, six datasets with distinct regular data spacing were extracted from this simulation: (i) 25x25; (ii) 100x100; (iii) 200x200; (iv) 400x400; (v) 800x800, and (vi) 1200x1200 meters along the X and Y directions, respectively. Third, 50 realizations using Sequential Gaussian Simulation (SGS) were generated for each one of these databases. The realizations were performed at point-support and resized to the block volume used for mining to upscale the realizations to block-support. Then, the Grade-Tonnage Curves of the realizations obtained with the different databases were calculated and compared. The resulting Grade-Tonnages were used to quantify the relationship between the drilling sampling and the uncertainty on the global mineral resources. The results showed that the uncertainty of the mineral resource decreases as the data spacing decreases. Depending on an acceptable uncertainty level, wider data spacings may be selected. So, the mineral exploration team can save on the budget and time to prepare the mineral resources inventory. This adequate drilling spacing may be defined using an acceptable uncertainty level. The illustration case demonstrates the intricacies and usefulness of the workflow proposed.

Key-words: geostatistics; Sequential Gaussian Simulation; data spacing uncertainty.

Sumário

I	Introdução	12
1.1	Meta	14
1.2	Objetivos específicos.....	14
1.3	Metodologia	15
1.4	Estrutura da dissertação	17
2	Revisão bibliográfica	18
2.1	Correção Estratigráfica	18
2.2	Métodos Geoestatísticos.....	20
2.2.1	<i>Análise Variográfica.....</i>	<i>21</i>
2.2.2	<i>Krigagem.....</i>	<i>22</i>
2.2.3	<i>Simulação Geoestatística.....</i>	<i>25</i>
2.3	Curvas de Parametrização – Teor-Tonelagem	30
2.4	Incertezas das estimativas minerais associadas ao tamanho das malhas de amostragem.....	30
2.5	Classificação de Recursos e Reservas.....	34
2.5.1	<i>Comissões para Declaração, Padronização e Classificação de Recursos e Reservas Minerais..</i>	<i>35</i>
2.5.2	<i>Métodos de Classificação.....</i>	<i>36</i>
3	Estudo de Caso.....	38
3.1	Análise preliminar dos dados	38
3.1.1	<i>Localização</i>	<i>38</i>
3.1.2	<i>Geologia Local.....</i>	<i>38</i>
3.1.3	<i>Análise Univariada.....</i>	<i>41</i>
3.2	Correção estratigráfica	44
3.3	Variografia	49
3.4	Simulação do modelo.....	52
3.4.1	<i>Modelo de blocos.....</i>	<i>52</i>
3.4.2	<i>Normalização dos dados</i>	<i>54</i>
3.4.3	<i>SGS</i>	<i>55</i>
3.4.4	<i>Retro_normalização.....</i>	<i>55</i>
3.4.5	<i>Validação das realizações.....</i>	<i>56</i>
3.5	Amostragem das n malhas regulares	59
3.6	Simulação usando as malhas regulares amostradas	61
3.6.1	<i>Retro-normalização</i>	<i>61</i>
3.6.2	<i>Reblocagem dos blocos.....</i>	<i>61</i>
3.7	Sumarização das incertezas.....	61
3.7.1	<i>Curva teor tonelagem das simulações.....</i>	<i>61</i>
3.7.2	<i>Classificação de Recursos</i>	<i>69</i>
4	Conclusões.....	74
5	Bibliografia.....	76

Figura 1-1 Fluxograma da metodologia realizada no estudo da incerteza associada as estimativas minerais perante a diversos espaçamento de malhas de amostragem	16
Figura 2-1 Correção Estratigráfica (Rubio et al. 2015).....	20
Figura 2-2 Semivariograma experimental convencional	22
Figura 2-3 - Relação Geral entre Resultados de Exploração, Recursos Minerais e Reservas Minerais (CBRR 2019).....	34
Figura 2-4 - Comissões pertencentes a CRIRSCO até agosto de 2019	36
Figura 3-1 - Mapa de localização do alvo de estudo	40
Figura 3-2 - Perfil Laterítico da Mina de bauxita – (Lage, 2018)	40
Figura 3-3 – Histograma Al_2O_3	42
Figura 3-4 – Histograma SiO_2	42
Figura 3-5 – Mapa de teores dos dados de Al_2O_3	43
Figura 3-6 – Mapa de teores dos dados de SiO_2	43
Figura 3-7 – Variogramas de Al_2O_3 em diversas direções com a topografia Real.....	46
Figura 3-8 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pelo topo.....	46
Figura 3-9 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pela base	46
Figura 3-10 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pela média das espessuras da lente modelada	46
Figura 3-11 – Variograma omni-direcional Al_2O_3 com topografia real.....	47
Figura 3-12 – Variograma omni-direcional Al_2O_3 com topografia corrigida pelo topo	47
Figura 3-13 – Variograma omni-direcional Al_2O_3 com topografia corrigida pela base	47
Figura 3-14 – Variograma omni-direcional Al_2O_3 com topografia corrigida pela média da espessura da camada modelada.....	47
Figura 3-15 – Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo topo	48
Figura 3-16 - Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo base	48
Figura 3-17 Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo média da camada	48
Figura 3-18 – Al_2O_3 - Variografias dos dados originais.....	50
Figura 3-19 – Al_2O_3 - Variografia dos dados normalizados	50
Figura 3-20 – SiO_2 - Variografias dos dados originais	51
Figura 3-21 – SiO_2 - Variografia dos dados normalizados.....	51
Figura 3-22 – Modelos de blocos dimensionados para as estimativas	53
Figura 3-23 - Dados de Al_2O_3 Normalizados	54
Figura 3-24 - Dados de SiO_2 Normalizados	54
Figura 3-25 - Mapa da simulação #1 de 50 da SGS para Al_2O_3	56
Figura 3-26 - Al_2O_3 - Reprodução dos histogramas das 50 SGSs (preto)e dos dados originais (vermelho)	58
Figura 3-27 - Al_2O_3 - Teste da acuracidade das 50 SGS	58
Figura 3-28 – Al_2O_3 - Reprodução do variograma horizontal das 50 SGSs (preto) e dos dados originais (vermelho)	58
Figura 3-29 – Al_2O_3 - Reprodução do variograma vertical das 50 SGSs (preto) e dos dados originais (vermelho)	58
Figura 3-30 - SiO_2 - Reprodução dos histogramas das 50 SGSs (preto)e dos dados originais (vermelho)	59
Figura 3-31 - SiO_2 - Teste da acuracidade das 50 SGS.....	59
Figura 3-32 – SiO_2 - Reprodução do variograma horizontal das 50 SGSs (preto) e dos dados originais (vermelho)	59
Figura 3-33 – SiO_2 - Reprodução do variograma vertical das 50 SGSs (preto) e dos dados originais (vermelho)	59
Figura 3-34 – Malhas de amostragem com distintos espaçamentos (m) – (a) 25x25x0.5, (b)100x100x0.5, (c) 200x200x0.5, (d) 400x400x0.5, (e) 800x800x0.5 e (f) 1200x1200x0.5.....	60
Figura 3-35 – Curvas de parametrização teor-tonelagem de Al_2O_3 para as malhas com distintos espaçamentos simulados 50 cenários para cada.....	62

Figura 3-36 – Curvas de parametrização teor-tonelagem de SiO_2 para as malhas com distintos espaçamentos simulados 50 cenários para cada.....	63
Figura 3-37 – Gráfico box-plot do valor da massa (% da massa total) de Al_2O_3 das 50 SGS para cada malha estudada para o teor de corte 46%.....	65
Figura 3-38 - Gráfico box-plot do valor da massa (% da massa total) de SiO_2 das 50 SGS para cada malha estudada para o teor de corte 4.4%.....	65
Figura 3-39 – Incerteza da massa de Al_2O_3 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 46%.....	67
Figura 3-40 - - Incerteza da massa de SiO_2 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 4,4%.....	67
Figura 3-41 - Incerteza do teor médio de Al_2O_3 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 46%.....	68
Figura 3-42 - Incerteza do teor médio de SiO_2 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 4,4%.....	68
Figura 3-43 – Proporção de blocos com valores de Al_2O_3 estarem +/- 15% da média c / 90% confiança para as massas de ROM referente ao período trimestral, (recurso medido) e período anual (recurso indicado).....	71
Figura 3-44 Proporção de blocos com valores de SiO_2 estarem +/- 15% da média c / 90% confiança para as massas de ROM referente ao período trimestral, (recurso medido) e período anual (recurso indicado).....	71
Figura 3-45 - Mapa da Classificação de Recursos Minerais do Depósito de Bauxita, (Recurso Medido - em vermelho, Recurso Indicado - em Amarelo, Recurso Inferido - em Azul, Collar dos furos - pontos pretos).....	73

Tabela 3-1- Al_2O_3 Sumário estatístico dados originais.....	42
Tabela 3-2 – SiO_2 Sumário estatístico dados originais.....	42
Tabela 3-3 – Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pelo topo.....	48
Tabela 3-4 - Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pela base.....	48
Tabela 3-5 - Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pela média da camada.....	48
Tabela 3-6 – Parâmetros do Modelo de Blocos.....	52
Tabela 3-7 – Parâmetros para amostragem das seis malhas para o estudo proposto.....	60
Tabela 3-8 - Classificação de Recursos do Depósito de Bauxita.....	73

1 Introdução

O principal objetivo econômico do setor da mineração é suprir a sociedade com recursos minerais para atender as suas diversas necessidades. O alumínio, como exemplo, é usado de inúmeras maneiras: meios de transporte: como elementos estruturais em aviões, barcos, automóveis, bicicletas, tanques, blindagens; embalagens: papel-alumínio, latas, embalagens *tetra-pak* e outras; construção civil: janelas, portas, divisórias, grades e outros; bens de uso: utensílios de cozinha, ferramentas; transmissão elétrica: uso em redes de transmissão elétricas de alta tensão é compensado pelo seu menor custo e densidade. Temos infindáveis outros elementos químicos de origem mineral que são imprescindíveis no nosso dia a dia.

Para se extrair um recurso mineral, é elaborado um engenhoso empreendimento o qual denominamos “mina”. A abertura de uma mina é um empreendimento de alto capital, o qual envolve cifras de milhões de dólares, muita mão de obra civil, grande interferência no meio ambiente e muitos outros aspectos a serem considerados. Ou seja, para se abrir uma mina é necessário de grande investimento de capital e requer uma decisão importante da sociedade para aceitá-la.

É fundamental, antes de qualquer outro fator, diagnosticar previamente a quantidade do elemento mineral que pode ser extraído de um provável projeto de mina para ajudar a definir a sua viabilidade. Essa etapa é conhecida como a fase da pesquisa mineral, onde se identifica um elemento mineral de interesse e através de estudos geológicos determina-se no fim desse ciclo de estudos a quantificação do recurso mineral.

O objetivo principal da fase da pesquisa mineral é ter uma declaração de recursos minerais, que desempenha um papel fundamental para decidir se o projeto de mineração é viável. Essas declarações seguem modernas especificações regidas por padrões e códigos internacionais (CRIRSCO, 2019).

Os recursos minerais são classificados como medidos, indicados ou inferidos, dependendo do grau de confiança nas estimativas. Além disso, os códigos incentivam a quantificação do risco e da incerteza da quantidade e qualidade dos recursos minerais.

Uma vez definido o recurso mineral, é realizado a avaliação de reservas que é a fase onde se aplica os fatores modificadores. Os fatores modificadores envolvem aspectos técnicos, econômicos, sociais e ambientais; e assim se avalia a sua viabilidade. A definição de recursos e reservas é revista periodicamente até o fim útil

da atividade da mina sempre que há novos dados para os seus parâmetros avaliativos (CRIRSCO, 2019).

A estimativa do recurso mineral é realizada a partir de um modelo normalmente interpolando os dados adquiridos. Vários métodos para realizar essa interpolação podem ser usados. Atualmente, os métodos mais difundidos na indústria mineral são os estimadores geoestatísticos univariados e lineares (Abzalov, 2016).

O estudo geoestatístico tem como ponto de partida um conjunto de observações que constituem uma amostra. As observações, de natureza quantitativa ou qualitativa, são usadas para inferir as propriedades do fenômeno espacial em estudo. Matheron (1963) fundamentou a geoestatística através de suas publicações sobre a Teoria das Variáveis Regionalizadas. Seus estudos foram inspirados a partir dos trabalhos de Krige (1951).

No entanto, muitas aplicações requerem uma medida de incerteza de um atributo em vários locais simultaneamente. Estas incertezas são produto de modelos que reproduzem a continuidade espacial dos dados. Esses modelos são obtidos através da simulação geoestatística (Goovaerts, 1997).

Existem diferenças entre estimar e simular. As estimativas tendem a reduzir a variância entre os locais estimados, causando suavizações nos valores extremos e modificando a continuidade espacial. Devido a isso, não é recomendado o uso de mapas gerados pela krigagem quando forem utilizados para aplicações sensíveis a presença de valores extremos, uma vez que esses modelos falham na reprodução de características críticas (Goovaerts 1997).

A simulação, por outro lado, reproduz a variabilidade original observada nos dados e combinando múltiplos modelos simulados pode-se avaliar a incerteza a respeito do atributo modelado. Isto implica que os valores extremos da distribuição original são preservados. O modelo de incerteza também fornece as ferramentas para análise de risco quando se aplica a ele uma função de transferência (Rossi & Deutsch, 2013). Uma função de transferência é realizada processando os dados simulados para obter indicadores de interesse, como por exemplo: obtermos valores da estimativa de recursos para cada simulação e o conjunto de todas demonstra uma variação nos resultados. Essa variação representa a incerteza da função de transferência para esse conjunto de possíveis cenários simulados.

Geralmente, a incerteza do modelo de recursos é menor quando os dados são mais densamente amostrados. No entanto, quanto mais adensada a malha de amostragem, mais investimento é necessário ao projeto.

O recurso mineral pode ser também definido como a tonelagem e o teor acima de um determinado teor de corte. Podemos quantificar a relação entre o

espaçamento da malha de sondagem (densidade da amostragem) e a incerteza dos recursos minerais através do uso da simulação da estimativa de recursos para vários espaçamentos de malhas de sondagem diferentes.

A mensuração da incerteza ajuda o tomador de decisões a selecionar o espaçamento de dados mais apropriado. O espaçamento de dados adequado é o que resulta em uma incerteza aceitável dos recursos e que adere ao orçamento e objetivos do projeto. Trabalhos relevantes abordando o uso de simulação geoestatística para medir a incerteza e sua relação com o espaçamento de dados podem ser encontrados na literatura (Deutsch & Beardow, 1999; Pilger *et al.*, 2001; Boucher *et al.*, 2004; Journel & Kyriakids, 2004; Wilde & Deutsch, 2013; Koppe *et al.* 2017).

1.1 Meta

Essa dissertação tem como meta investigar a influência associada a distintas malhas de amostragem na declaração de recursos minerais.

1.2 Objetivos específicos

A fim de atingir a meta proposta os seguintes objetivos foram delineados:

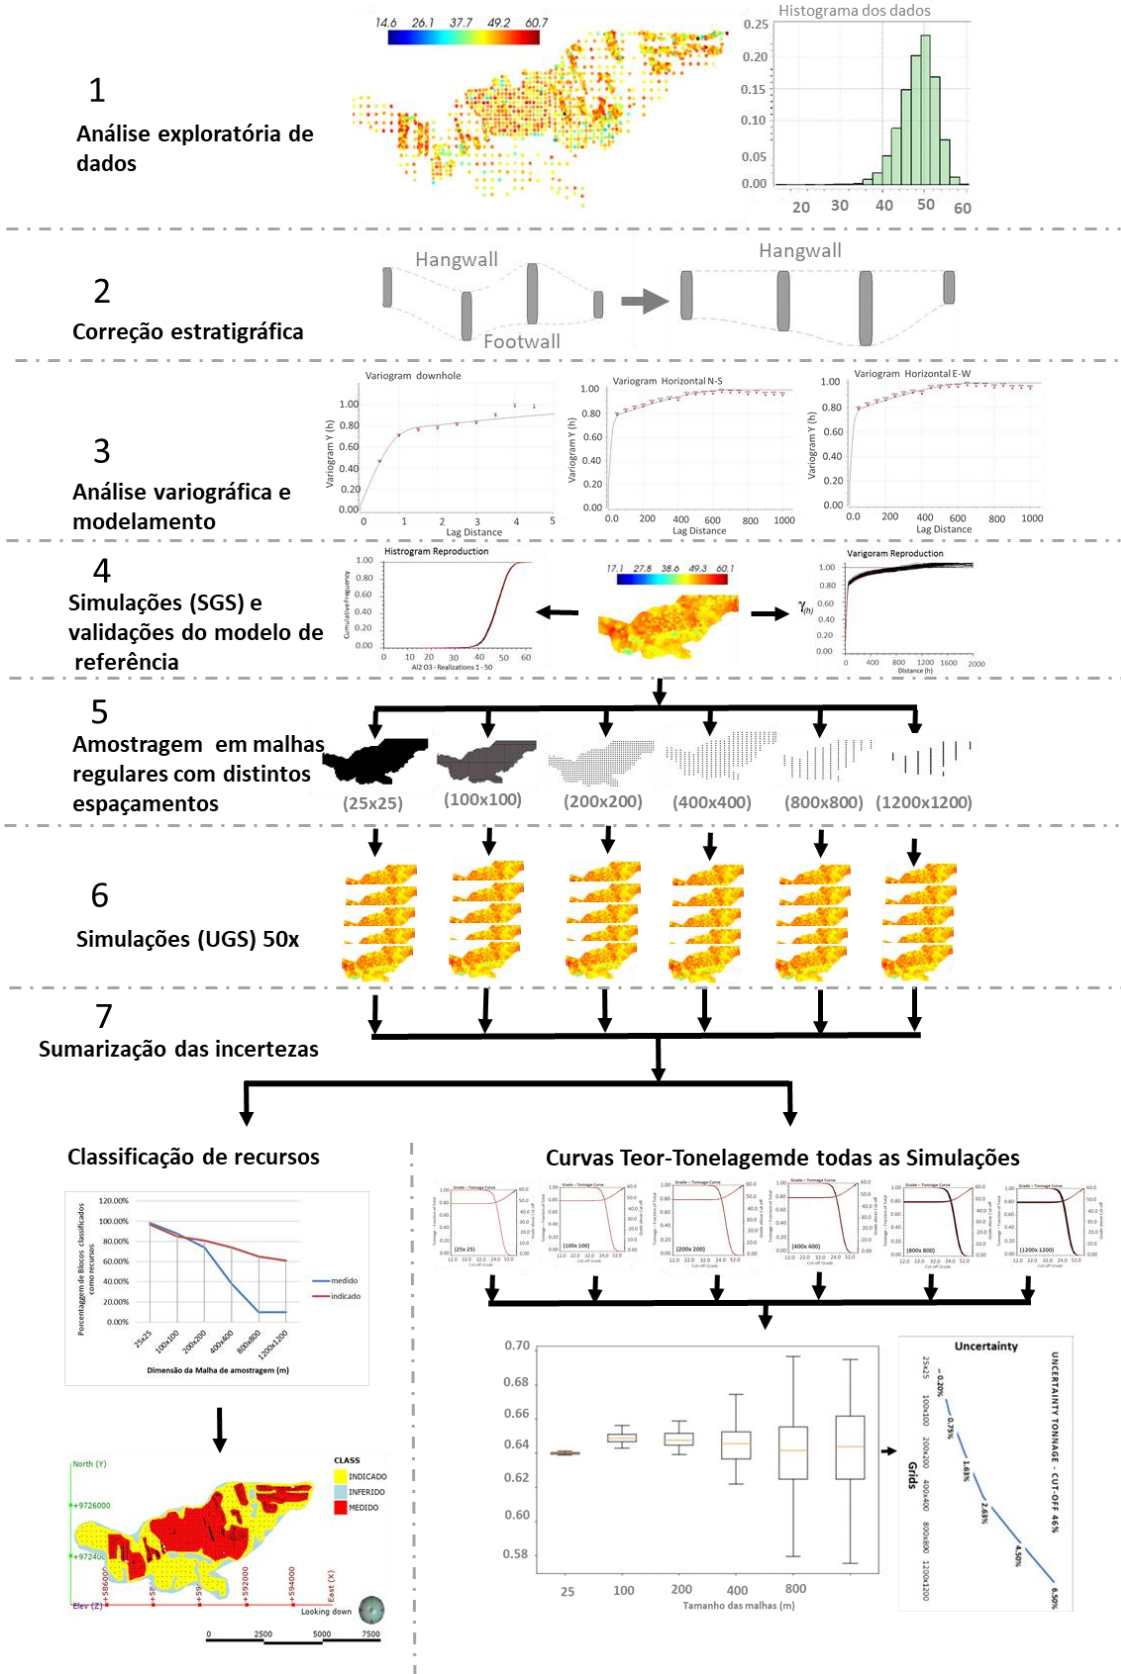
- Desenvolver uma metodologia para inferir a incerteza dos recursos minerais para diferentes espaçamentos amostrais;
- Conduzir um estudo de caso em um banco de dados de um grande depósito mineral real e verificar a incerteza dos recursos minerais para cada dimensão de malha de sondagem determinada, empregando como função de transferência as curvas teor-tonelagem e a classes de classificação dos recursos minerais.

1.3 Metodologia

A metodologia investiga como a incerteza dos recursos minerais é influenciada por distintos espaçamentos de malhas de sondagem e consiste nas seguintes etapas (Figura 1-1):

- I. Análise exploratória de dados;
- II. Correção das coordenadas z pela posição estratigráfica;
- III. Análise e modelamento variográfico;
- IV. Gerar realizações e escolher uma como sendo o modelo de referência;
- V. Amostrar o modelo de referência simulado em espaçamentos regulares n vezes para obter bases de dados com diferentes espaçamentos amostrais;
- VI. Realizar simulação geoestatística utilizando os n bancos de dados com espaçamentos regulares;
- VII. Mensurar as medidas de incerteza dos recursos para cada malha de sondagem avaliada.
 - Calcular as curvas teor-tonelagem para todas as realizações;
 - Classificar os recursos minerais;

Figura 1-1 Fluxograma da metodologia realizada no estudo da incerteza associada as estimativas minerais perante a diversos espaçamento de malhas de amostragem



1.4 Estrutura da dissertação

O capítulo 2 revisa os conceitos de correção de coordenadas cartesianas para coordenadas estratigráficas e conceitos de geoestatística como: análise variográfico, krigagem, simulação estocástica, curvas de parametrização (teor-tonelagem) e métodos de classificação de recursos. Além disso, o capítulo 2 revisa o uso de simulação geoestatística para medir incerteza em função da quantidade de dados.

O capítulo 3 demonstra e comenta os resultados obtidos a partir da aplicação do método de simulação sequencial gaussiana para avaliar a incerteza associada a distintas dimensões de malhas de sondagem e aplicação de classificação de recursos com o uso dos aplicativos dos softwares GSLIB, SGeMS e scripts em linguagem *Python*.

O Capítulo 4 resume os principais resultados e comenta as conclusões obtidas com esse trabalho.

2 Revisão bibliográfica

2.1 Correção Estratigráfica

Depósitos minerais como bauxita, carvão, manganês e alguns depósitos de lateritas de níquel são constituídos principalmente por extensas camadas mineralizadas. Essas camadas formadas por processos de sedimentação ou intemperismo podem passar por vários eventos geológicos subsequentes, como dobras, erosões e / ou formação de bacias. Um dos problemas mais comuns para avaliação nesse tipo de depósito é a análise de continuidade espacial. Esta continuidade espacial pode ser afetada por distorções causadas pela combinação de amostras de diferentes níveis estratigráfico. Um caminho para minimizar esse efeito é a correção estratigráfica (Pyrzcz & Deutsch, 2014).

O uso de coordenadas estratigráficas é conveniente nos casos de depósitos sedimentares estratificados, onde a mineralização tem maior continuidade ao longo da unidade estratigráfica de interesse. As coordenadas cartesianas originais X, Y, Z são transformadas em um Sistema de Coordenadas Estratigráficas (SCE). Todos os cálculos de estimativas são realizados no SCE, e depois elas são voltadas para as coordenadas cartesianas do mundo real (Rossi & Deutsch, 2014).

Rubio *et al.* (2015) cita que nos anos 80 e 90, alguns autores demonstraram interesse em usar coordenadas estratigráficas (Rendu & Readdy, 1982; Weber, 1982-1990; Dagbert *et al.*, 1984). McArthur (1988) usou a transformação de coordenadas cartesianas em coordenadas estratigráficas em um depósito de urânio na Austrália, atribuindo arbitrariamente números estratigráficos para a nova coordenada vertical Z. Desde então, alguns estudos mostraram sistematicamente o processo de transformar as coordenadas cartesianas em coordenadas estratigráficas em estudos de casos geoestatísticos (Koppe *et al.* 2006; Rubio, *et al.*, 2015).

Pyrzcz & Deutsch (2014) sugerem algumas aproximações que podem ser feitas para transformar coordenadas cartesianas em coordenadas estratigráficas. Uma coordenada vertical será definida como a distância relativa ao topo de uma superfície ou à base. Isso permitirá inferir medidas naturais de correlação horizontal e preservar a estrutura geológica no modelo numérico final (Pyrzcz & Deutsch, 2014). As novas coordenadas verticais podem ser calculadas usando a *Equação 1*:

$$Z(i)_{str} = \left(\frac{Z(i) - Z(i)b}{Z(i)t - Z(i)b} \right) * T \quad \text{Equação 1}$$

onde:

- $Z(i)_{str}$ = Z elevação após correção estratigráfica na amostra i ;
- $Z(i)$ = elevação real de Z na amostra (i);
- $Z(i)b$ = elevação Z (i) da amostra da base da camada;
- $Z(i)t$ = elevação Z (i) da amostra do topo da camada;
- T = espessura média da camada;

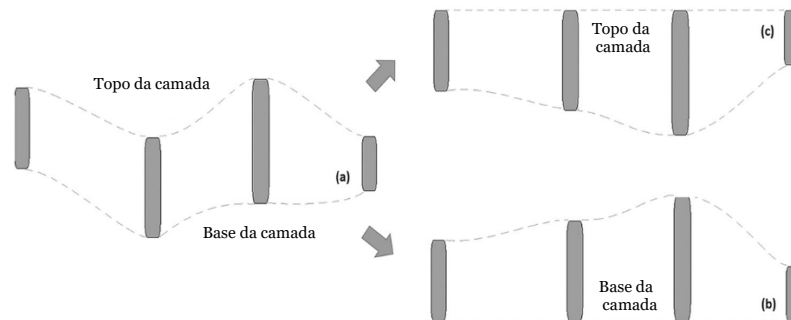
A camada mineralizada que apresenta pequenas mudanças de espessura ao longo da sua extensão é atribuída a equação redefinida como segue, (Equação 2 & Equação 3) (Pyrz & Deutsch, 2014) :

$$Z(i)_{str} = Z(i) - Z(i)b \quad i = 1, \dots, n \quad \text{Equação 2}$$

$$Z(i)_{str} = Z(i)t - Z(i) \quad i = 1, \dots, n \quad \text{Equação 3}$$

As Equação 2 e Equação 3 representam as mudanças para coordenadas estratigráficas realizadas usando como referências de correção de distância à base e ao topo da camada, respectivamente. Essa transformação não muda as distâncias horizontais entre amostras, que podem, nos casos em que as camadas são dobradas fortemente, modificar a continuidade horizontal determinada pelos valores de amostras levando a erros na determinação dos variogramas. O uso dessa transformação apresentada é apropriado para depósitos que mostrem apenas ligeiro dobramento ao longo das camadas. A Figura 2-1 mostra a transformação de uma camada geológica estratiforme cujas coordenadas no eixo vertical são transformadas e as coordenadas estratigráficas corrigidas pela base e topo da camada.

Figura 2-1 Correção Estratigráfica (Rubio et al. 2015)



Uma boa maneira para escolher o método de correção estratigráfica é validação cruzada (Isaaks & Srivastava, 1989). O método consiste em remover momentaneamente uma amostra posicionada no local (i) do conjunto de dados original. A variável de interesse é estimada nesse local (i) usando as informações das amostras restantes. Finalmente, a diferença entre o valor estimado e o valor real no mesmo local (i) é calculada. Essa diferença é conhecida como o erro de estimativa. O processo é repetido para todas as amostras no conjunto de dados. O método de correção estratigráfica a ser adotado é aquele que resulta em um erro de estimativa médio mais próximo de zero e em um menor desvio padrão do erro de estimativa.

2.2 Métodos Geoestatísticos

Os dados provenientes da Ciência da Terra, como teores de elementos metálicos, características geotécnicas, porosidade e permeabilidade de rochas, concentração de poluentes em uma pluma de contaminação entre outros não são aleatórios. Esses dados apresentam uma continuidade espacial. Ao se observar um mapa de dados espacialmente localizados, é comum se observar regiões de alto e baixo valor. Em outras palavras, amostras de alto teor tendem a estar mais próximas a outras amostras de alto valor. Essa propriedade foi descrita a partir dos trabalhos de Matheron (1965) e é conhecida como teoria das variáveis regionalizadas.

A teoria da variável regionalizada tem dois objetivos: descrever a correlação espacial (Análise Variográfica) e resolver problemas de estimativa de uma variável com base em uma amostra (Estimativa por Krigagem). A krigagem utiliza a correlação espacial para calcular os pesos que as amostras recebem. Amostras com maior correlação espacial com o ponto a ser estimado em geral recebem pesos maiores.

2.2.1 Análise Variográfica

O variograma é a ferramenta primordial de suporte às técnicas de krigagem, que permite representar quantitativamente a variação de um fenômeno regionalizado no espaço (Matheron, 1963).

O nível de dependência espacial entre duas variáveis regionalizadas é representado pelo variograma, $2\gamma(h)$, o qual é definido como a esperança matemática do quadrado da diferença entre os valores de pontos no espaço, separados pelo vetor distância h :

$$2\gamma(h) = E\{[Z(u) - Z(u + h)]^2\} = Var[Z(u) - Z(u + h)] \quad \text{Equação 4}$$

Através de uma amostra $z(u_i)$, $i=1, 2, \dots, n$, o variograma pode ser estimado por:

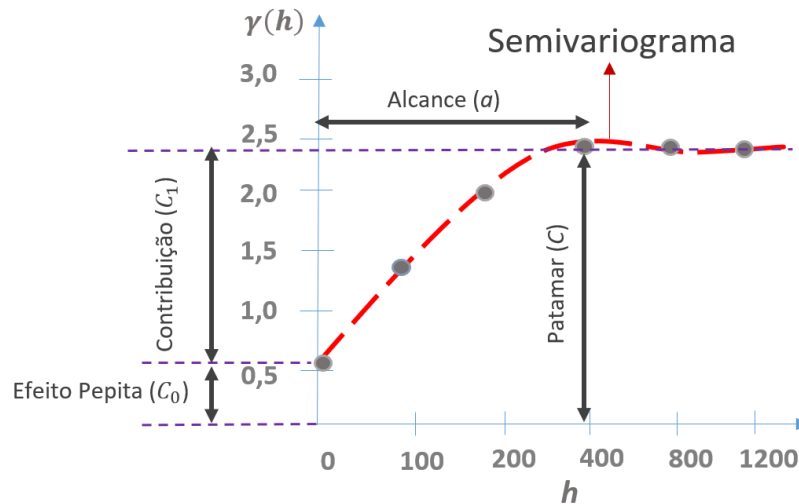
$$2\gamma(h) = \frac{1}{N(h)} \sum_{i=1}^{N(h)} [Z(u_i) - Z(u_i + h)]^2 \quad \text{Equação 5}$$

Onde:

- $2\gamma(h)$ - é o variograma estimado;
- $N(h)$ - é o número de pares de valores medidos, $z(u_i)$ e $z(u_i+h)$, separados por um vetor distância h ;
- $z(u_i)$ e $z(u_i+h)$, - são valores da i -ésima observação da variável regionalizada, coletados nos pontos u_i e u_i+h ($i = 1, \dots, n$), separados pelo vetor h .

Um semivariograma experimental é ilustrado na Figura 2-2. O seu padrão representa o que, intuitivamente, se espera de dados de campo, isto é, que as diferenças $[Z(u_i) - Z(u_i + h)]$ cresçam à medida que h , a distância que os separa cresce. É esperado que observações mais próximas entre si sejam mais semelhantes do que aquelas separadas por maiores distancias. Desta maneira, é esperado que $\gamma(h)$ aumente com a distância h .

Figura 2-2 Semivariograma experimental convencional



Onde:

- Alcance (a): distância dentro da qual as amostras apresentam-se correlacionadas espacialmente;
- Patamar (C): é o valor do semivariograma correspondente a seu alcance (a). Deste ponto em diante, considera-se que não existe mais dependência espacial entre as amostras, porque a variância da diferença entre pares de amostras ($\text{Var}[Z(u) - Z(u+h)]$) torna-se invariante com a distância;
- Efeito Pepita (C_0): à medida que h tende para 0 (zero), $\gamma(h)$ se aproxima de um valor positivo chamado Efeito Pepita (C_0), que revela a descontinuidade do variograma para distancias menores do que a menor distância entre as amostras. Parte desta descontinuidade, pode ser também devida a erros de medição (Isaaks & Srivastava, 1989), mas é difícil quantificar se a maior contribuição provém dos erros de medição ou da variabilidade de pequena escala não captada pela amostragem.;
- Contribuição (C_1): é a diferença entre o patamar (C) e o Efeito Pepita (C_0).

2.2.2 Krigagem

O termo krigagem, tradução do francês krigeage e do inglês kriging - foi cunhado pela escola de geoestatística francesa em homenagem a Daniel G. Krige, engenheiro de minas sul-africano e pioneiro na aplicação de técnicas estatísticas em avaliação mineira.

Krigagem é um processo geoestatístico de estimativa de valores de variáveis distribuídas no espaço e/ou tempo, com base em valores adjacentes quando considerados interdependentes pela análise variográfica. Pode ser comparado com os métodos tradicionais de estimativa por médias ponderadas ou por médias móveis, mas a diferença fundamental é que somente a krigagem apresenta estimativas não

tendenciosas e a mínima variância associada ao valor estimado (Matheron, 1963).

Considera-se o método de Krigagem do tipo BLUE - *Best Linear Unbiased Estimator* - Melhor Estimador Linear Não-Enviesado (Isaaks & Srivastava, 1989): é linear porque as suas estimativas são combinações lineares dos dados existentes; é não enviesada, pois a média dos erros (desvios entre o valor real e o valor estimado) é nula; é a melhor porque minimiza a variância do erro de estimativa. A krigagem é um estimador linear a partir da informação disponível, onde temos $z(u)$ posições desconhecidas e dados nas posições $z(u_\alpha)$ como realizações da variável regionalizada em estudo (Goovaerts, 1997).

$$Z^*(u) - m(u) = \sum_{\alpha=1}^{n(u)} \lambda_\alpha(u) [Z(u_\alpha) - m(u_\alpha)] \quad \text{Equação 6}$$

Onde:

- $Z^*(u)$ = valor estimado no local u ;
- $m(u)$ = média do atributo Z no local u ;
- $\lambda_\alpha(u)$ = pesos a serem determinados;
- $m(u_\alpha)$ = média do atributo Z no local u_α ;

A krigagem é um termo genérico associado a um conjunto de métodos de estimativa, os quais incluem: krigagem simples (SK), krigagem ordinária (OK), krigagem indicadora (IK), krigagem universal (UK), krigagem múltipla de indicadores (MIK) e krigagem com deriva externa (KED) (Sinclair & Blackwell, 2004). Cada método possui restrições/considerações matemáticas próprias e, portanto, um sistema de equações específico. Entretanto, todos são baseados no mesmo princípio, ou seja, ausência de enviesamento e variância do erro de estimativa mínima.

O termo krigagem abrange um conjunto de métodos, sendo os mais usuais para este trabalho SK e OK e as definições desses métodos estão bem detalhadas, em Isaaks & Srivastava (1989) e Rossi & Deutsch (2014).

2.2.2.1 Krigagem simples

O propósito da krigagem é determinar um conjunto de pesos ideais que minimizem a variância do erro de estimativa. Considere um estimador linear (Rossi & Deutsch, 2014):

$$Z^*(u) = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot [z(u_{\alpha}) - m] + m = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot z(u_{\alpha}) + \left[1 - \sum_{i=1}^n \lambda_{\alpha}\right] m \quad \text{Equação 7}$$

onde: $z(u_{\alpha})$ são os valores dos n dados nos locais u_{α} e $Z^*(u)$ é a estimativa. A média m é considerada conhecida e estacionária. Neste caso, o estimador Krigagem Simples (SK) é não enviesado por definição, e a estimativa é realizada com efeito nos valores dos dados residuais. A média conhecida m é subtraída dos valores dos dados e eles são adicionados ao banco de dados novamente após os valores residuais terem sido estimados.

2.2.2.2 Krigagem ordinária

A krigagem ordinária (OK) é baseada na mesma estimativa linear de variação de erro mínima em um local onde o valor real é desconhecido. Mas ao contrário de SK, OK não assume que a média é constante para toda a área de estudo. A krigagem ordinária assume que a média é constante apenas dentro da vizinhança de busca. Ao exigir a imparcialidade global a Krigagem Ordinária (OK) restringe a soma dos pesos a 1.0, e como resultado, a média não precisa ser conhecida. A OK realiza a estimativa com precisão local em deterioramento da precisão global.

Ao estimar um valor $Z^*(u)$ em (u) , usando os valores dos dados $z(u_{\alpha})$ de n amostras vizinhas nas localizações u_{α} e combinando-os linearmente com os pesos λ_{α} , o estimador para $Z^*(u)$ é obtido (Rossi & Deutsch, 2014):

$$Z^*(u) = \sum_{\alpha=1}^n \lambda_{\alpha} z(u_{\alpha}) \quad \text{Equação 8}$$

Onde:

- $Z^*(u)$ – Valor a estimar no local u ;
- λ_{α} - Peso que é dado a cada um dos valores observados da variável no lugar u_{α} ;
- $z(u_{\alpha})$ - Valor em pontos amostrados perto do local a ser interpolado;
- Os pesos são calculados de tal forma que o estimador seja não enviesado e tenha a mínima variância do erro.

2.2.3 Simulação Geoestatística

Independentemente das razões, é importante reconhecer que as estimativas não são perfeitas, no sentido em que sempre existirá um erro associado a elas, ou seja, uma incerteza. A proposta básica dos algoritmos de simulação geoestatística é permitir o modelamento da incerteza pela geração de múltiplas realizações de valores de atributos distribuídos no espaço, em um processo conhecido como simulação estocástica (Journel, 1974).

Essas realizações alternativas vão alimentar funções de transferência com diferentes graus de complexidade, permitindo obter-se uma distribuição de possíveis respostas, sendo que a amplitude de variação dessa distribuição caracteriza o que convencionou-se chamar de espaço de incerteza.

Segundo Deutsch & Journel (1998), entre as características esperadas dos modelos simulados, particularmente para aplicações na área de mineração, espera-se que:

- Honrem os valores nos pontos amostrados;
- Reproduzam as mesmas características de dispersão dos dados originais, isto é, o histograma e o variograma, sendo dessa forma ditos simulados condicionalmente.

No entanto, nenhum algoritmo de simulação é flexível o suficiente para permitir a reprodução de toda a variedade de feições e padrões estatísticos encontrados na prática. Além disso, os próprios modelos estatísticos apresentam uma incerteza associada, já que são inferidos de amostras limitadas em tamanho e número. Essas discrepâncias entre as realizações e o modelo estatístico adotado são referidas como flutuações ergódicas (Deutsch & Journel, 1998).

2.2.3.1 Estimativa versus simulação

Deutsch & Journel (1998) explicam que a maioria dos algoritmos de interpolação, incluindo a krigagem, o objetivo é fornecer a melhor estimativa local de uma variável ou seu padrão de comportamento sem considerar especificamente a estatística espacial das estimativas. Na simulação, a reprodução de características globais e estatísticas (histograma, covariância) tem precedência sobre a precisão local, fornecendo representações globais alternativas cuja reprodução de padrões de continuidade espacial prevalece. Por outro lado, a krigagem fornece um conjunto de representações locais, onde prevalece a precisão local em detrimento da precisão global.

A escolha entre krigagem e simulação deve ser decidida com base no que é

mais relevante para cada aplicação: o mínimo de erro da estimativa local (precisão local) obtida pela krigagem ou a continuidade espacial correta (precisão global) obtida pela simulação estocástica, que por sua vez, assume que cada realização é equiprovável e o histograma da amostragem é bom o suficiente para representar o histograma real, ou seja, que amostragem fornece boa aproximação do real (Olea, 1999).

A técnica probabilística de simulação condicional fornece diversas realizações possíveis de um depósito, cada uma representa o depósito simulado de maneira similar ao depósito real e apresenta as mesmas características geológicas e geoestatísticas. Algumas das aplicações das simulações condicionais são: estudo da quantidade de amostras para um determinado objetivo e avaliação preliminar de recursos e reservas minerais potenciais em corpos de minério com poucas amostras; estudo de sensibilidade de estimativa de recurso e reserva; estudo detalhado da sensibilidade de recuperação de recursos geológicos in-situ, como a unidade mínima de lavra (Journal, 1980; Sinclair & Blackwell, 2004).

2.2.3.2 Espaço de incerteza

A distribuição (histograma) dos valores, resposta correspondentes ao conjunto de realizações, fornece uma medida da incerteza resultante do nosso conhecimento imperfeito sobre a distribuição no espaço do parâmetro ou variável de trabalho.

Segundo Deustsch & Journel (1998) e Journel (1974), essa distribuição é o espaço de incerteza e pode ser utilizada para análises de risco e tomada de decisão. A extensão ou o tamanho do espaço de incerteza depende de vários fatores, tais como:

- A quantidade (número de dados condicionantes) e qualidade das informações de entrada disponíveis: quanto mais dados são usados para condicionar as realizações, mais similares ao modelo adotado tornam-se as estatísticas das realizações. A definição dos critérios de busca define quais os dados (iniciais e simulados) que devem ser considerados dentro da vizinhança de cada ponto a ser simulado;
- Da função de transferência utilizada;
- Do número de realizações: Bonato *et al.* (2000) recomendam começar com um número pequeno de realizações e incrementar esse número até que os momentos estatísticos possam ser caracterizados como ergódicos;
- Analogamente, Deutsch & Journel (1998) estabelecem que esse

número deve ser tal que permita mapear a incerteza do parâmetro em estudo. A reprodutibilidade do histograma e variograma aumenta com o incremento do número de realizações, sendo que os algoritmos de simulação sequencial gaussiana permitiriam atingir um patamar de estabilização mais rapidamente do que os algoritmos baseados em simulação de indicadores;

- Dos parâmetros do variograma e das dimensões da malha (grid) da simulação: as flutuações ergódicas dos variogramas das realizações são de difícil reprodução quando o alcance (range) do modelo variográfico for grande em relação ao tamanho da área simulada, particularmente se o efeito pepita (*nugget effect*) for pequeno.

2.2.3.3 SGS - Simulação sequencial Gaussiana

A Simulação Sequencial Gaussiana (SGS) (Isaaks, 1990), assume o modelo multi-Gaussiano. Na simulação sequencial Gaussiana, as cdfs (*conditional cumulative distribution function* - função de distribuição cumulativa condicional) locais são Gaussianas e os parâmetros são determinados pela krigagem simples (Deutsch & Journel, 1998). Os parâmetros da função de distribuição condicional são:

- A média condicional, que é o valor da variável estimada por krigagem simples;
- A variância condicional, que é a variância de krigagem simples;
- A utilização da krigagem simples ocorre porque se assume que a variável simulada é estacionária, ou seja, a média constante para a área em estudo e a covariância entre duas amostras só depende do vetor de separação.

A simulação sequencial pode ser aplicada para qualquer função de distribuição condicional, desde que seus parâmetros possam ser determinados pela krigagem simples.

Para que qualquer tipo de função randômica possa ser aplicado na simulação sequencial Gaussiana, é necessário fazer a transformação dessa função em uma função Gaussiana multivariada. Na prática, os dados são transformados em uma distribuição Gaussiana univariada utilizando a transformação *normal score* (Deutsch & Journel, 1998) e se assume que os dados transformados seguem uma distribuição Gaussiana multivariada.

Essa transformação é válida desde que preserve o modelo de covariância. Segundo Deutsch & Journel (1998), a função randômica Gaussiana multivariada $Y(u)$ é caracterizada se:

- Os seus subconjuntos também forem Gaussianos multivariados;
- A combinação linear das variáveis randômicas for Gaussiana;
- Se duas variáveis forem não correlacionadas, ou seja, a covariância entre elas for nula, elas também são independentes;
- As distribuições condicionais de uma variável randômica, determinadas por outras variáveis randômicas que foram simuladas, forem normais.

O algoritmo da SGS envolve as seguintes etapas:

- Transforme os dados originais Z em uma distribuição Gaussiana padrão;
- Determine um caminho aleatório que visite todos os nós do grid uma única vez;
- Visite a localização u e calcule o valor local e a variância por krigagem simples usando os m dados vizinhos (originais e previamente simulados):

$$Y^*(u) = \sum_{\alpha=1}^n \lambda_{\alpha} [Y(u_{\alpha})] \quad \text{Equação 9}$$

$$\sigma_{SK}^2(u) = C(0) - \sum_{\alpha=1}^n \lambda_{\alpha} C(u, u_{\alpha}) \quad \text{Equação 10}$$

Onde:

- $Y^*(u)$ = valor da krigagem simples no local u
 - $Y(u_{\alpha})$ = Valor em pontos amostrados perto do local a ser interpolado;
 - λ_{α} = pesos da krigagem simples
 - $\sigma_{SK}^2(u)$ = variância de krigagem simples
 - $C(0)$ = Sill do variograma (é igual a 1)
 - $C(u, u_{\alpha})$ = covariância entre o local u e o local u_{α}
 - λ_{α} = pesos da krigagem simples
- Selecione randomicamente um resíduo R(u) de uma distribuição Gaussiana com média zero e variância igual a variância de krigagem simples;
 - Adicione o valor krigado ao resíduo para obter o valor simulado:

$$Y_s(u) = Y^*(u) + R(u) \quad \text{Equação 11}$$

- Y_s poderia ser obtido diretamente via tiragem randômica de uma distribuição normal com média $Y^*(u)$ e variância $\sigma_{SK}^2(u)$;
- Adicione $Y_s(u)$ aos demais dados originais e previamente simulados para garantir que a covariância entre esse valor e todos os próximos a serem

obtidos seja correta. Esse é o ponto chave da simulação sequencial, a adição dos valores anteriores para reproduzir a covariância entre todos os nós do grid;

- Retro transformar os dados simulados em todos os nós a escala original;
- Repetir o processo inteiro criando outra realização com um número de semente randômica distinto.

2.2.3.4 Normalização dos dados

A normalização (transformação dos dados para uma distribuição normal ou Gaussiana padrão) é empregada para que os dados sejam utilizados em técnicas que assumem que a distribuição deles seja normal.

Diferentes caminhos estão disponíveis para essa transformação: quantil-quantil, baseado em polinômios (*hermitian polynomials*), etc. A técnica mais simples e mais eficiente é a transformação Gaussiana (Φ) obtida graficamente, conhecida como transformação *normal score*, a qual é gerada de uma correspondência quantil-quantil entre a distribuição normal padrão e a distribuição dos dados, conforme algoritmo de Deutsch & Journel (1998).

A **Erro! Fonte de referência não encontrada.** ilustra uma distribuição da transformação direta quantil-quantil.

$$\varphi(y) = y_i = G^{-1} [F(Z_i)], i = 1, \dots, \quad \text{Equação 12}$$

Onde: F é a estimativa da cdf dos dados;

G é a cdf da distribuição Gaussiana padrão;

ε é um número positivo muito pequeno ($\ll 1$ para evitar que $G^{-1}(1) = \infty$)

A função da distribuição Gaussiana padrão é definida no intervalo $-\infty, +\infty$, mas na prática é suficiente usar o intervalo $[-7.0, +7.0]$.

O limite inferior (Z_{\min}) é zero ou o valor mínimo do banco de dados e Z_{\max} é igual ou maior que o maior valor do banco de dados. Note que um valor alto artificialmente estabelecido para Z_{\max} implicará na criação de valores altos quando os valores forem retro-transformados.

A transformação normal score é sensível a alguns fatores:

- A transformação é baseada em uma estimativa da distribuição dos dados, que pode ser derivada de um banco de dados agrupado;
- A retro-transformação é sensível à escolha do limite superior Z_{\max} ;

- A transformação é sensível a picos na distribuição dos dados.

2.3 Curvas de Parametrização – Teor-Tonelagem

As curvas Teores-Tonelagens são uma representação visual do impacto dos teores de corte nas reservas minerais. As curvas de Tonelagem e Teores exibem a tonelagem acima do teor de corte e teor médio de um depósito em relação ao teor de corte. O teor de corte é usado para classificar o material em estéril ou minério. O material com teor acima do teor de corte é considerado minério, enquanto o material com teor abaixo do teor de corte é considerado estéril.

À medida que os critérios para classificação de minério se tornam mais seletivos (teor de corte aumenta), a tonelagem acima do teor de corte diminui e o teor médio acima do teor de corte aumenta. As curvas mostram, em última instância, como a média e a tonelagem de um material entregue a um determinado processo dependem do teor de corte selecionado.

A tonelagem do material extraído que não será processado também é determinada pelo teor de corte selecionado. As curvas de tonelagem são aplicáveis em vários estágios da avaliação de depósito. Durante a exploração, por exemplo, elas podem ser usadas para estimar o tamanho geral de um recurso em toneladas de minério e de metal, usando dados de exploração para gerar as estimativas.

Os dados de teores e tonelagem usados para criar as curvas são compilados com várias suposições, que devem ser levadas em consideração ao usar as curvas. Tais suposições são que o depósito é classificado corretamente, os dados representam o recurso *in situ* completo e os dados representam um depósito único ou vários depósitos pequenos que são considerados como um único depósito.

2.4 Incertezas das estimativas minerais associadas ao tamanho das malhas de amostragem

As atividades de sondagem na mineração são as principais fontes para a amostragem geoquímica dos depósitos minerais. A aquisição dessas informações para a modelagem do corpo mineral consome a maior parte do orçamento e tempo do projeto de pesquisa mineral. Assim, é importante que o espaçamento de dados seja otimizado para reduzir as incertezas no modelo geológico, no inventário de recursos minerais e nas despesas do empreendimento. Geralmente, a incerteza do modelo das estimativas é menor quando os dados são mais densamente amostrados. No entanto, uma malha de amostragem mais densa sempre é mais

cara.

Trabalhos relevantes já abordaram o uso de simulação geoestatística para medir a incerteza associada com diferentes tamanhos de amostragem dos dados na mineração, como por exemplo, Deutsch & Beardow (1999), Pilger *et al.* (2001), Boucher *et al.* (2004), Journel & Kyriakids (2004), Wilde & Deutsch (2013), Verly *et al.* (2014), e Koppe *et al.* (2017).

A metodologia é similar entres todos os autores com os seguintes passos:

- Simulação geoestatística de um modelo de teores do depósito da variável de estudo que represente os teores verdadeiros;
- Amostragem desse modelo de teores em malhas com dimensões diversas na escala de interesse da análise, por exemplo: dimensões de 25x25, 50x50, 100x100, 500x500;
- Simulação geoestatística usando as malhas amostrais obtidas no passo anterior;
- A malha de amostragem ideal é aquela a que contém o menor grau de incerteza considerando os limites de orçamento previstos no projeto.

Geralmente a diferença entre as metodologias entre os diversos autores ocorre devido ao tipo de simulação utilizada e pela forma de mensuração do grau de incerteza avaliada de acordo com a função de transferência que é o objeto da análise do estudo.

Englund & Heravi (1993) discutem uma metodologia para determinar a quantidade de amostras que resultariam no menor custo total para um projeto de remediação. Essa metodologia usa a SGS para gerar um modelo simulado. Presume-se que este modelo represente a verdade e várias quantidades de dados são amostradas a partir dele. A krigagem em bloco é então realizada usando as amostras e o custo total do projeto determinado. O custo do projeto considera o custo de amostragem e custo de remediação, bem como o custo da contaminação residual. Esse processo é repetido várias vezes para diferentes quantidades de dados, resultando em uma curva de quantidade de dados de custo adicional. A quantidade de dados que minimiza o custo é considerada ótima.

Deutsch & Beardow (1999) propõem uma metodologia para determinar o espaçamento ideal da perfuração em um depósito de areias petrolíferas. Eles propõem o uso de krigagem por bloco ou simulação estocástica para avaliar a incerteza em todos os locais dentro de uma área de interesse para um determinado espaçamento de dados. O valor esperado da incerteza em todos os locais é retido para o espaçamento de dados fornecido. Esse processo é repetido para muitos espaçamentos de dados, permitindo descobrir a relação entre incerteza e

espaçamento de dados. A contabilização do custo da perfuração e do custo da incerteza permite determinar um espaçamento ideal da perfuração.

Pilger (2000) utilizou simulação para acessar a incerteza de cada local, que foi quantificada por diferentes índices de incerteza. Pilger *et. al* (2002) adicionam amostras, uma de cada vez, nas regiões de elevada incerteza e mostram o efeito na redução da incerteza, após a adição de cada informação, nos recursos classificados de um depósito de carvão.

Journel & Kyriakidis (2004) e Wilde (2010), descrevem uma metodologia para avaliar reservas minerais. Essa metodologia envolve a simulação de realizações em suporte pontual da variável de interesse. Essas realizações de suporte pontual desempenham dois papéis na metodologia: 1) são usadas como base para simular dados que serão obtidos futuramente na operação de mina (chamados de dados futuros) e 2) são reblocadas para o tamanho de bloco usado na lavra (esse valor é considerado o valor real da variável de interesse no suporte de bloco). Os dados obtidos futuramente imitam, por exemplo, os dados de furos de desmonte que são usados para selecionar os blocos de estéril e minério. As estimativas de seleção futura são geradas a partir da krigagem por bloco usando os dados futuros simulados previamente. As estimativas de seleção futura são usadas para classificar o bloco em minério ou estéril e determinar o lucro. Esse processo é repetido para muitas realizações para determinar a incerteza no lucro. Eles sugerem que as análises de sensibilidade sejam realizadas variando a qualidade e a densidade dos dados de seleção futura para avaliar o impacto no lucro.

Boucher *et al.* (2004) propõem uma técnica para avaliar o adensamento da amostragem. Seu método usa os dados disponíveis para gerar uma realização estocástica do atributo geológico. Essa realização, chamada de depósito real, é amostrada com os diferentes esquemas de adensamento de amostragem da variável de interesse. Para cada esquema de amostragem, várias realizações dos atributos geológicos são geradas condicionalmente as amostras simuladas. Essas realizações, incluindo o depósito real, são calculadas em bloco para a escala desejada. Indicadores econômicos são usados para classificar os blocos. As classificações simuladas são comparadas aos reais para muitos esquemas de diferentes adensamentos de amostragem para avaliar a sensibilidade dos resultados. Esta metodologia quantifica o *trade-off* entre o custo dos erros de classificação e o adensamento da amostragem.

Koppe (2009) analisou a eficiência do incremento de amostras com distintas configurações a uma malha pré-definida. Para cada configuração amostral realizou-se simulações por banda rotativas e a incerteza foi avaliada mensurando o Valor Presente Líquido do projeto (VPL). Em suas conclusões, foi observado que os

fatores que mais influenciaram na incerteza foram o coeficiente de variação (CV) da variável em estudo e a assimetria dos dados. Ambos, quanto maiores, maior é a incerteza das simulações. Koppe *et al.* (2011) complementa esses estudos mostrando que a incerteza global das simulações é menor em distribuições de amostras regulares, enquanto a incerteza local das simulações é menor quando a adições de amostragem é feita de forma irregular especificamente em locais de alto alcance de interquartil (IQR) (onde IQR excede 80% do percentil).

Wilde (2010) e Wilde & Deutsch, (2013) descrevem uma metodologia para entender a relação entre espaçamento (ou densidade) de dados e a incerteza. O conhecimento sobre um atributo geológico está relacionado à quantidade e qualidade das observações do atributo. A incerteza existe devido à falta de conhecimento e não é uma característica inerente ao atributo geológico. Assim, a incerteza é reduzida à medida que o conhecimento e qualidade dos dados coletados aumentam. É realizada uma simulação como modelo a ser imputado como verdadeiro, desse modelo é realizado a amostragem de cinco malhas com distintos espaçamentos, e então cada malha foi simulada 50x e reblocadas para um tamanho de blocos padrão. Como função de transferência para medir a incerteza foi usado gráficos do tipo *boxplot*, o desvio padrão, o coeficiente de variação, a diferença entre percentis P90 e P10, precisão e probabilidade de classificação incorreta.

Koppe *et al.* (2017), baseado em Goovaerts (2001), Pilger *et al.* (2001); Li *et al.* (2004); Emery *et al.* (2008); Koppe *et al.* (2011) discutem os fatores que influenciam esse erro de estimativa:

- O primeiro fator é o espaçamento da malha de amostragem, o erro geralmente diminui quando mais informações (ou um espaçamento menor da amostra) estão disponíveis para a estimativa;
- O segundo fator é a variabilidade dos valores da variável de estudo ao longo do depósito mineral, maior CV, maior erro associado;
- O terceiro fator é a geometria do bloco (volume e dimensões), uma vez que o valor do atributo para um bloco com volume maior, por exemplo, tende a ser mais fácil de estimar.

Koppe *et al.* (2017) sugere que, em média, o erro de estimativa é semelhante para casos com características semelhantes em termos espaçamento amostral, CV, geometria de blocos e modelo de continuidade espacial para a distribuição dos valores dos atributos ao longo do depósito. Koppe *et al.* (2017) e Drumond *et al.* (2019) apresentam alguns gráficos para prever o erro associado a estimativa de um atributo geológico em um bloco que será minerado para teores de Au, Ni, Al e Cu. Esses gráficos podem ser usados para atributos com características semelhantes.

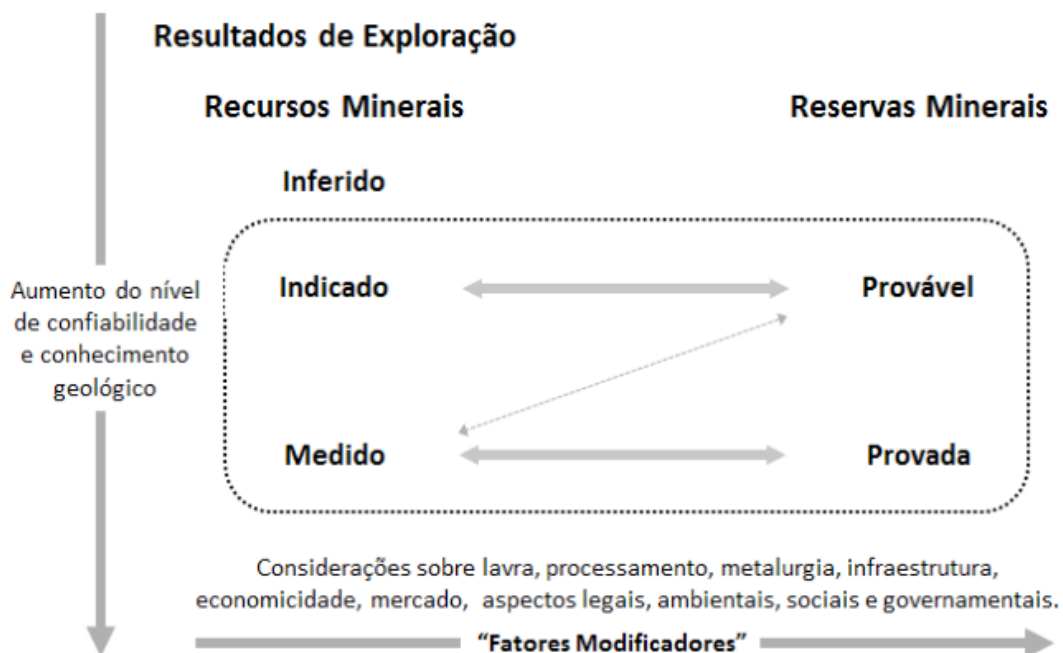
2.5 Classificação de Recursos e Reservas

Os principais métodos de classificações de recursos e reservas adotadas estão baseadas fundamentalmente na confiança geológica. Tais classes usam o grau de certeza como fator discriminante entre as várias classes.

De acordo com a tendência atual, reservas são partes dos recursos que são viáveis tecnologicamente e economicamente no momento da sua determinação. Resumindo, os recursos são classificados de acordo com o nível crescente de pesquisa e de conhecimento do depósito, em: inferido, indicado e medido (CBRR 2019) (Figura 2-3). O único parâmetro econômico no cálculo desses recursos é o teor de corte, fundamental para definição prévia da viabilidade de um depósito.

A partir de estudos de viabilidade do depósito, considerando-se fatores econômicos, de mineração, metalúrgicos, mercadológicos, legais, ambientais, sociais e políticos, os recursos indicados e medidos poderão vir a transformar-se em reservas prováveis e provadas, respectivamente.

Figura 2-3 - Relação Geral entre Resultados de Exploração, Recursos Minerais e Reservas Minerais (CBRR 2019)



2.5.1 Comissões para Declaração, Padronização e Classificação de Recursos e Reservas Minerais

Devido a ocorrência de escândalos de fraude, como o caso "Bre-X", em 1996 na Indonésia, países com tradição em mineração e comercialização internacional de *commodities* minerais voltaram-se para a criação de Comitês Nacionais. Esses comitês estabelecem as boas práticas para declaração das informações oficiais dos recursos e reservas minerais de empresas de mineração listadas em bolsas de valores.

As práticas se fundamentam em instrumentos que versam sobre os resultados de exploração, avaliação de recursos e reservas, por meio da condução, execução, assinatura e responsabilidade de um profissional experiente, competente, qualificado, habilitado e pertencente à organização profissional reconhecida (*CP - Competent Person / QP - Qualified Person*).

O objetivo é aumentar a confiança financeira e operacional para os investidores e partes interessadas. Dentre os instrumentos internacionais, devido as maiores bolsas de valores que possuem investimentos em projetos de mineração, os mais difundidos são os seguintes:

- JORC - *The Australasian Code for Reporting of Exploration Results, Mineral Resources and Ore Reserves*;
- NI 43-101 - *National Instrument 43-101, from Canadian Securities Administrator of Canada & CMI – Canadian Institute of Mining, Metallurgy and Petroleum*.

Em 1994, foi fundado o *Committee for Mineral Reserves International Reporting Standards* (Crisco) com o objetivo de fomentar o estabelecimento das boas práticas nas demais regiões do globo (Figura 2-4).

A similaridade dos vários códigos e diretrizes nacionais de relatórios permitiu à CRIRSCO desenvolver um Modelo de Código de Relatórios de Minerais Internacionais, disponível em: <http://www.crisco.com>

Figura 2-4 - Comissões pertencentes a CRIRSCO até agosto de 2019



Fonte: <http://www.criusco.com/welcome.asp>

2.5.2 Métodos de Classificação

Todas as diretrizes dos códigos propostos discutem a continuidade geológica e do teor como os principais componentes dos critérios de classificação, às vezes adicionando fatores modificadores para se ajustar as condições locais. É decisão do Profissional Qualificado (QP) quanto a evidência aceitável dessa continuidade, que pode depender parcialmente da experiência prévia do QP com esse tipo de depósito (Rossi & Deutsch, 2014). Um equívoco comum é que os métodos de classificação de recursos fornecem uma avaliação objetiva da confiança; na verdade, a classificação é uma expressão da opinião de um QP (Rossi & Deutsch, 2014).

Uma prática comum é usar a distância entre os furos para os blocos estimados como critério de definição de classes de recursos (Silva & Boisvert, 2014). A escolha dos critérios geométricos deve basear-se na prática comum para o tipo de depósito, local específico e um avaliador especialista. Os benefícios de usar medidas de distância simples são que os critérios podem ser simplesmente declarados, e é um processo transparente, fácil de entender. Algumas das preocupações mais comuns declaradas contra esses tipos de métodos são que elas são excessivamente simplistas, pois não conseguem captar totalmente a confiança geológica.

Os métodos geométricos de classificação geralmente não fornecem uma

medida real de incerteza. Há um interesse crescente em quantificar a incerteza em diferentes volumes (bloco a bloco, se possível), o que leva a avaliações de risco relevantes (Sousa, 2007).

Yamamoto (1999), Souza (2007) fazem uma cuidadosa revisão dos métodos clássicos que não envolvem o uso da incerteza das estimativas para a classificação de recursos minerais.

Souza (2007) classificam os recursos e avaliam a incerteza desses a partir do uso da simulação por bandas rotativas, foi usado como função de transferência o erro da variância condicional para classificar os recursos em medidos, indicados e inferidos.

Houve um movimento em direção a métodos sistemáticos e padronizados para avaliar e apresentar a incerteza das estimativas (Dohm, 2005). Aspectos comuns de declaração da incerteza incluem especificação da população ou amostra sendo considerada, medida de incerteza "+ / -", probabilidade de estar dentro do valor estimado "+ / -", e uma lista de suposições e componentes da incerteza.

Existem três aspectos a serem considerados na classificação de recursos (Rossi e Deutsch, 2014):

- Volume;
- Medida de incerteza "+ / -" e probabilidade de estar dentro da medida "+ / -" de incerteza;
- O formato do relatório de incerteza deve ser claro e compreensível.

Por exemplo, Verly *et al.* (2014) propõem que os volumes trimestrais ou mensais de produção onde o teor deve estar dentro de 15% do teor previsto, 90% do tempo são definidos como recursos medidos e volumes anuais de produção onde o teor deve estar dentro de 15% do teor previsto 90% do tempo são definidos como recursos indicado.

Silva & Boisvert (2014), demonstra a sensibilidade dos resultados da classificação de recursos para diferentes parâmetros de precisão ao redor do teor global e a acurácia dos resultados. Quanto mais alta for os parâmetros de precisão e acurácia menores serão as massas dos recursos a serem declarados.

Não há regras ou diretrizes estabelecidas para decidir sobre esses parâmetros para a classificação de recursos. Essa decisão de parâmetros permanece nas mãos da pessoa qualificada, que justificará a melhor decisão que foi tomada (Rossi & Deutsch, 2014).

3 Estudo de Caso

Essa dissertação de mestrado tem como meta investigar o grau de incerteza associada a distintos espaçamentos de malhas de amostragem para a mensuração do recurso mineral em um depósito de bauxita. Para atingir esse objetivo sete etapas foram desenvolvidas e serão descritas a seguir.

3.1 Análise preliminar dos dados

3.1.1 Localização

O alvo deste estudo está no extremo centro Oeste do estado do Pará. Ela encontra-se dentro da unidade de relevo denominada de Bacia Sedimentar Amazônica e, mais especificadamente, no planalto rebaixado da Amazônia – Médio Amazonas (Figura 3-1). Esta área é caracterizada pela presença, na planície fluvial do Rio Amazonas, de platôs com 100 a 160 m de altitude, em cujos topos se encontram os depósitos de Bauxita Laterítica e por uma região intermediária formada por pequenas colinas, com altitudes de 35 a 90 m, que circundam estes platôs.

3.1.2 Geologia Local

A mineralização da bauxita é formada por processos lateríticos típicos de zonas tropicais que começaram no início da era Cenozóica, atuando sobre arenitos imaturos e argilitos formando camadas extensas em formações de platô quilométricas. O capeamento de argila não mineralizada varia de 0,5 a 12 metros nesta camada.

Os depósitos de bauxita da Amazônia Oriental são considerados tipo “blanket” (Patterson, 1967), são formados “in situ” por processos de intemperismo em rochas sedimentares clásticas, sob condições climáticas tropicais úmidas. Estes depósitos caracterizam-se por apresentar espessura de ordem métrica, e por apresentarem acentuadas variações de alumínio, sílica e ferro.

O depósito de bauxita alvo deste estudo corresponde a um horizonte laterítico localizado no topo da sequência litológica e pode ser dividido em três zonas distintas: argila, zona de laterita concrecionária e argila variegada. A zona laterítica pode ser subdividida em três subzonas: Bauxita Nodular, Laterita Ferruginosa e Bauxita Maciça

(Lage, 2018).

O perfil litológico da área da mina de Juruti é descrito e ilustrado na Figura 3-2, topo para base, tem-se:

- Solo Orgânico: Formado por material decomposto, apresenta espessura média de 30 cm.
- Argila de decapeamento: Espessura varia de 1 a 12m, composta por argila amarela a amarela escura, ou também chamada de Argila Belterra.
- Bauxita Nodular: Esse horizonte pode chegar a uma espessura de 6m e é representado por nódulos de gibbsita de tamanho variado dentro de uma matriz caulínica.
- Laterita ferruginosa: A espessura desta camada pode variar de poucos centímetros a 3m. Esse horizonte é bem característico por causa da presença de altas concentrações de Fe_2O_3 .
- Bauxita Maciça: Trata-se de um horizonte com espessura de poucos centímetros a 6m, formado essencialmente por gibbsita, hematita e caulinita.
- Argila Variegada: Composto de argila caulínica de cores variegadas, predominando o avermelhado e o arroxeadado, eventualmente alguma gibbsita.

O nível da Bauxita Maciça é o minério explorado e alvo do estudo desta dissertação.

Figura 3-1 - Mapa de localização do alvo de estudo

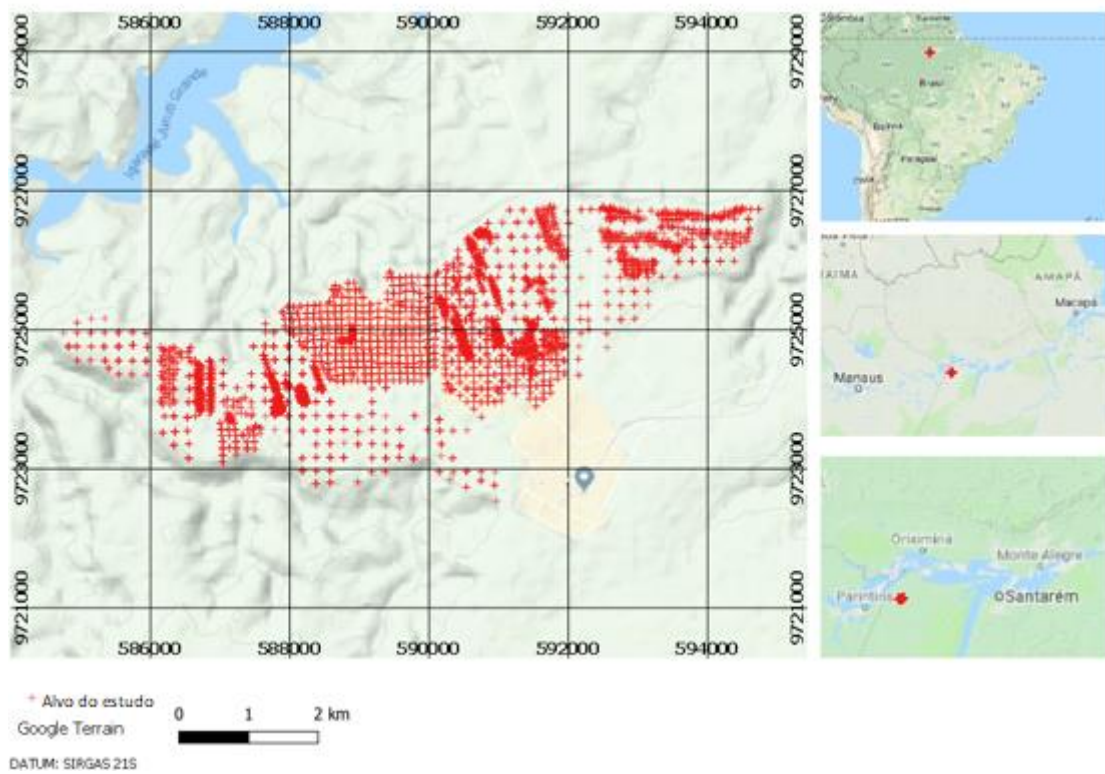



Figura 3-2 - Perfil Laterítico da Mina de bauxita – (Lage, 2018)



3.1.3 Análise Univariada

Esta dissertação trabalha com banco de dados de uma empresa de mineração de bauxita presente em um dos grandes platôs de bauxita da Amazônia brasileira, no centro oeste do estado do Pará. Esses dados cobrem aproximadamente uma área irregular de 10 km no eixo leste-oeste e 4,5 km no eixo norte-sul, totalizando aproximadamente 20 km². Existem quatro tamanhos de malha de sondagem:

- 200 x 200 m, abrange principalmente o leste e oeste da área;
- 100 x 100 m, principalmente no centro da área;
- 50 x 50 m em alguns locais;
- e 25 x 25 m em áreas bem restritas.

Na base do perfil laterítico, foi modelada como minério o nível de bauxita maciça, esta camada mineralizada tem espessura máxima de 8 m e 1,5 m em média. Além disso, foram perfurados 2784 furos compostos por 7609 amostras geoquímicas com tamanho médio de 0,5 metros.

As espécies químicas analisadas e estudada nesta dissertação foram:

- Alumina disponível (Al_2O_3 - relacionado ao conteúdo de gibbsita representando as análises químicas mais importantes para a bauxita);
- e sílica reativa (SiO_2) - relacionado ao conteúdo de caulinita representando o componente deletério metalúrgico mais importante).

O sumário estatístico de Al_2O_3 tem teores, no máximo, 60,71%; mínimo 14,62%; mediana 49%; média 48,50%; variância 18,9; desvio padrão 4,35; coeficiente de variação 0,09, e curtose 6,24. Por sua vez, o resumo estatístico de teores de SiO_2 tem, no máximo, 12,13%; mínimo 0,04%; mediana 3,27%; média 3,59%; variância 14,63; desvio padrão 2,15; coeficiente de variação 0,60 assimetria 0,44 e curtose 2,34 (Figura 3-3 a 3-6, Tabela 3-1 a 3-2).

Para evitar viés nas estatísticas devido a amostragem agrupadas, com uma maior densidade de pontos amostrais em alguns locais do que em outros, foi realizada o desagrupamento dos dados.

O método *cell declustering* foi proposto por (Journel, 1983) e o primeiro código público amplamente utilizado foi disponibilizado pelo autor (Deutsch, 1989). Uma versão desse código (declus) está disponível em (Deutsch & Journel, 1998) e foi usada, resultando em um conteúdo médio de Al_2O_3 de 47,25% e SiO_2 4,2%, cada dado

recebeu seu peso de desagrupamento devido no banco de dados. O tamanho da célula usada para o desagrupamento foi aquele que obteve a menor média dentre vários testados pelo método do declus, neste caso 350 metros.

Figura 3-3 – Histograma Al₂O₃

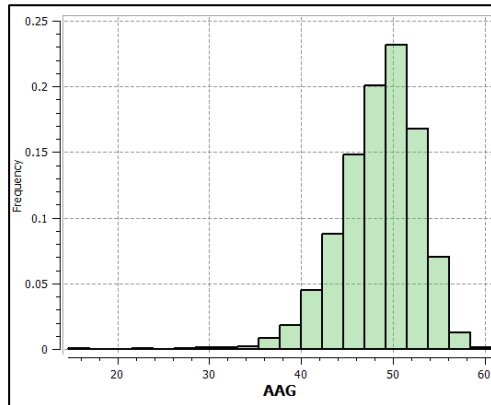


Tabela 3-1- Al₂O₃ Sumário estatístico dados originais

Número de dados	7609
Máximo	60.71%
Mínimo	14.62%
Média	48.50%
Mediana	49.00%
Variância	18.90
Coefficiente de variação	0.09
Skewness	4.35
kurtosis	6.24

Figura 3-4 – Histograma SiO₂




Tabela 3-2 – SiO₂ Sumário estatístico dados originais

Número de dados	7609
Máximo	12.13%
Mínimo	0.04%
Média	3.58
Mediana	3.27 %
Variância	4.6
Coefficiente de variação	0.60
Skewness	0.44
kurtosis	-0.66

Figura 3-5 – Mapa de teores dos dados de Al_2O_3


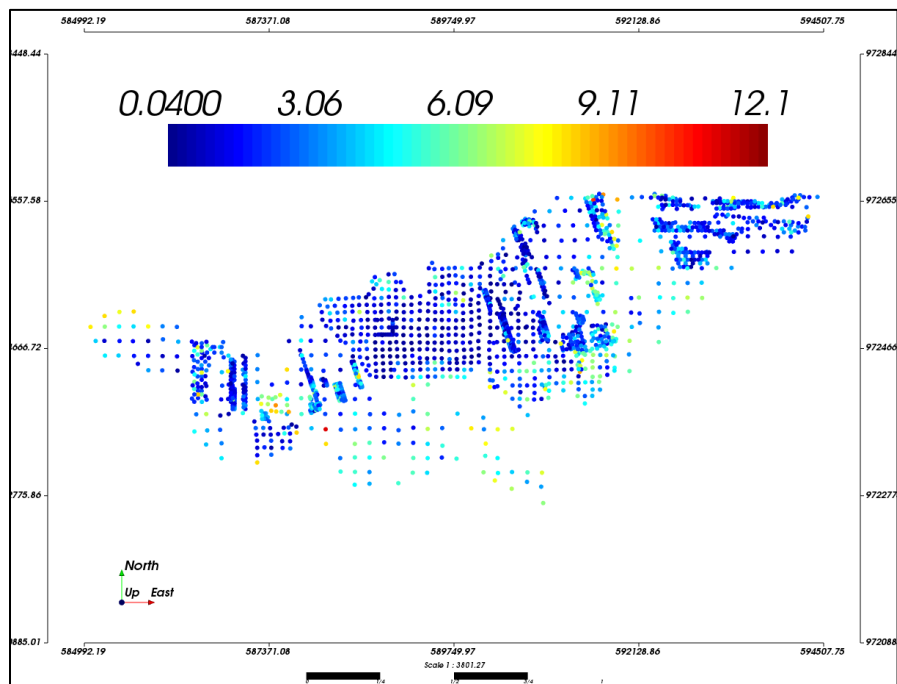


Figura 3-6 – Mapa de teores dos dados de SiO_2



3.2 Correção estratigráfica

Depósitos minerais como bauxita são constituídos principalmente por grandes camadas mineralizadas formadas por processos de intemperismo. Um dos problemas mais comuns para este tipo de depósito é a análise de continuidade espacial que pode ser afetada por um erro causado pela combinação de amostras de diferentes níveis estratigráficos (Rubio *et al.*, 2015).

Implementando as fórmulas apresentadas por Pyrcz & Deutsch (2014) em um aplicativo com script Python ao banco de dados do alvo em estudo, realizou-se a correção estratigráfica em referência ao topo, base e média da espessura da camada de bauxita maciça. Obteve-se as novas três referências para as coordenadas Z com correções estratigráfica pelo topo, base e média da camada.

As variografias do Al_2O_3 em todas as direções foram feitas para analisar a continuidade espacial dos seus teores considerando as coordenadas Z real, Z corrigida pelo topo, Z corrigida pela base e Z corrigida pela média das camadas. Em consequência, os resultados do conjunto dessas variografias mostram que:

- O conjunto de variogramas utilizando a coordenada Z real (Figura 3-7) apresenta uma dispersão com variância maiores e alcances menores, quando comparado com o conjunto de variogramas com correção estratigráfica (Figuras 3-7 a 3-10). Isso demonstra que para este alvo é importante o uso da correção estratigráfica para a coordenada Z;
- O conjunto de variogramas com correção estratigráfica pelo topo apresenta uma dispersão menor em comparação ao conjunto de variogramas com correção estratigráfica pela base para alcances até 700 metros;
- O conjunto de variogramas com correção estratigráfica pela média da espessura das amostras possui uma dispersão menor em relação a todos os outros.

Realizou-se então, a variografia omni-direcional no plano horizontal de Al_2O_3 para as coordenadas Z real, e as coordenadas Z com os três tipos de correção estratigráfica conforme ilustrado nas Figuras 3-11 a 3-14. Com essas informações variográficas foi executado uma estimativa por krigagem ordinária para Al_2O_3 para cada tipo das quatro coordenadas Z.

Com os resultados dessas estimativas foi feita uma validação cruzada, com

Al_2O_3 e as correções estratigráficas para mensurar o erro médio e variância do erro.

O erro médio e variância do erro é ilustrado nos histogramas (Figuras 3-15 a 3-17) e nos sumários de histograma do erro (Tabelas 3-3 a 3-5). Com elas interpreta-se que:

- A variância do erro e média do erro para a correção estratigráfica pela média da espessura da camada são ligeiramente menores que a correção estratigráfica pelo topo e pela base.
- A variância do erro da correção estratigráfica pelo topo é ligeiramente menor que a variância do erro da correção estratigráfica pela base, e ambas possuem a mesma média do erro.
- A formação das camadas de bauxita segue a tendência do nível freático que é responsável pelo intemperismo, isso faz a diferenciação dos estágios de intemperismo ocorra na direção do topo para base. Esse é um fator geológico que contribui para a correção estratigráfica seja feita pelo topo.

A correção estratigráfica pela média da espessura da camada de bauxita maciça seria a melhor opção a ser adotada. Porém, a média da espessura faz com que, no espaço estratigráfico, o depósito tenha uma espessura constante. Assim, por ser importante para o estudo a característica do alvo em 3D, optou-se por usar o banco de dados com a correção estratigráfica pelo topo.

Figura 3-7 – Variogramas de Al_2O_3 em diversas direções com a topografia Real




Figura 3-8 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pelo topo

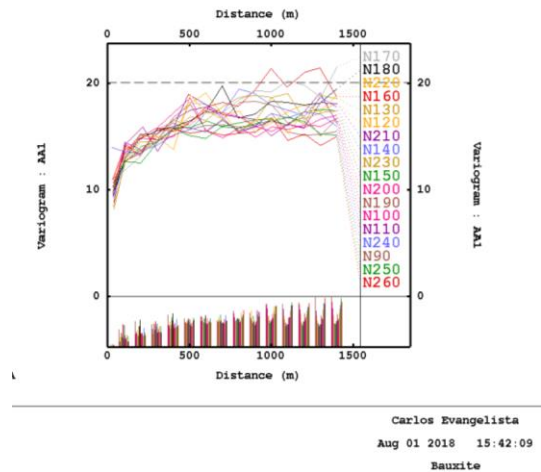


Figura 3-9 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pela base




Figura 3-10 – Variogramas de Al_2O_3 em diversas direções com a topografia corrigida pela média das espessuras da lente modelada




Figura 3-11 – Variograma omni-direcional Al_2O_3 com topografia real

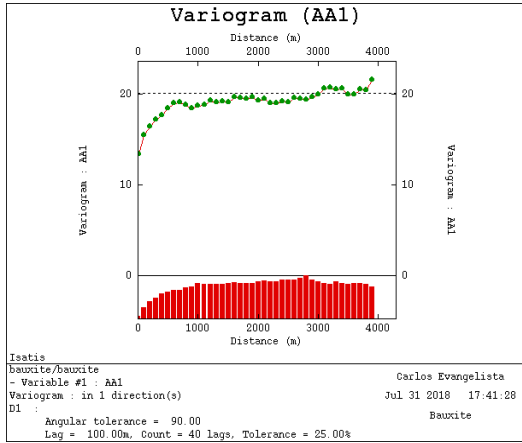


Figura 3-12 – Variograma omni-direcional Al_2O_3 com topografia corrigida pelo topo




Figura 3-13 – Variograma omni-direcional Al_2O_3 com topografia corrigida pela base




Figura 3-14 – Variograma omni-direcional Al_2O_3 com topografia corrigida pela média da espessura da camada modelada




Figura 3-15 – Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo topo

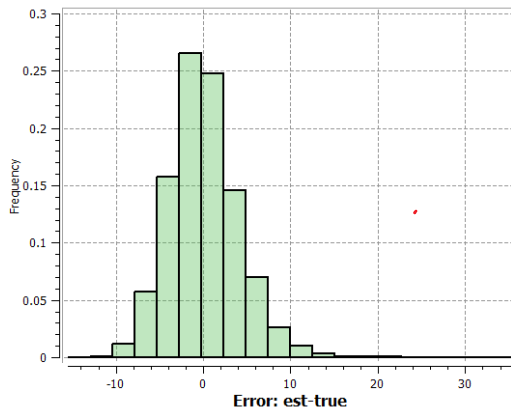


Tabela 3-3 – Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pelo topo

Número de dados	7609
Máximo	35.38
Mínimo	-15
Média	0.116
Mediana	-0.169
Variância	16.44

Figura 3-16 - Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo base




Tabela 3-4 - Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pela base

Número de dados	7609
Máximo	36,65
Mínimo	-17.054
Média	0.116
Mediana	0.234
Variância	18.07

Figura 3-17 Histograma do erro da validação cruzada entre os dados originais e estimativa OK pela correção estratigráfica pelo média da camada




Tabela 3-5 - Sumário estatístico Al_2O_3 da validação cruzada– dados originais x estimativa correção estratigráfica pela média da camada

Número de dados	7609
Máximo	38.09
Mínimo	-16.24
Média	0.110
Mediana	-0.232
Variância	15.05

3.3 Variografia

O banco de dados com resultados de teores de Al_2O_3 e SiO_2 e com correção estratigráfica pelo topo da camada de bauxita maciça foram adotados para a análise da continuidade espacial. A análise da continuidade espacial dos dados de Al_2O_3 e SiO_2 foram feitas através da variografia no software SGeMS (Remy *et al.*, 2011) para os dados originais e para os dados originais normalizados (nscore).

Dentro todas as análises variográficas para o alvo de estudo, foram eleitas as seguintes como principais (Figuras 3-18 e 3-21 e Equações 13 a 16):

$$\gamma(h) = 0.95 + shp \left\{ 13,68 \left(\frac{(N-S)/0^0}{65 m} + \frac{(E-W)/0^0}{65 m} + \frac{vert.}{1.1 m} \right) + 4.37 \cdot \left(\frac{(N-S)/0^0}{840 m} + \frac{(E-W)/0^0}{840 m} + \frac{vert.}{10 m} \right) \right\}$$

(Al₂O₃ dados originais) Equação 13

$$\gamma(h) = 0.05 + shp \left\{ 0.72 \left(\frac{(N-S)/0^0}{50 m} + \frac{(E-W)/0^0}{50 m} + \frac{vert.}{1.4 m} \right) + 0.23 \cdot \left(\frac{(N-S)/0^0}{760 m} + \frac{(E-W)/0^0}{760 m} + \frac{vert.}{10 m} \right) \right\}$$

(Al₂O₃ dados normalizados) Equação 14

$$\gamma(h) = 0.3 + shp \left\{ 3 \left(\frac{(N-S)/0^0}{70 m} + \frac{(E-W)/0^0}{70 m} + \frac{vert.}{1.5 m} \right) + 4.37 \cdot \left(\frac{(N-S)/0^0}{500 m} + \frac{(E-W)/0^0}{500 m} + \frac{vert.}{2.4 m} \right) \right\}$$

(SiO₂ dados originais) Equação 15

$$\gamma(h) = 0.07 + shp \left\{ 0.65 \left(\frac{(N-S)/0^0}{70 m} + \frac{(E-W)/0^0}{70 m} + \frac{vert.}{1.4 m} \right) + 0.28 \cdot \left(\frac{(N-S)/0^0}{500 m} + \frac{(E-W)/0^0}{500 m} + \frac{vert.}{2,4 m} \right) \right\}$$

(SiO₂ dados normalizados) Equação 16

Figura 3-18 – Al₂O₃ - Variografias dos dados originais

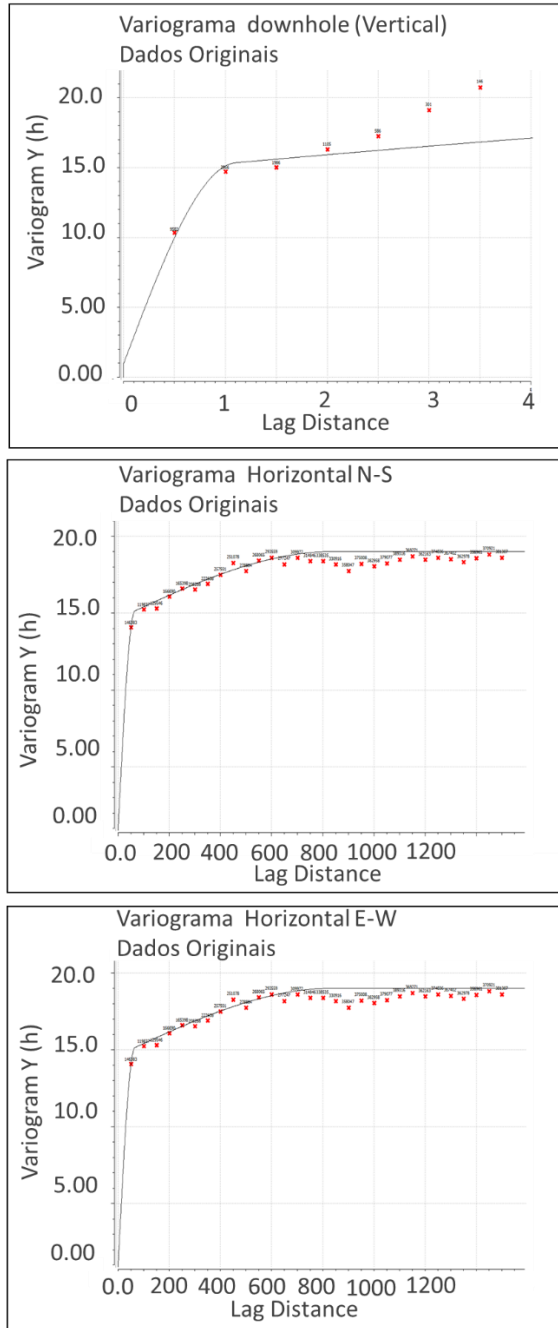


Figura 3-19 – Al₂O₃ - Variografia dos dados normalizados

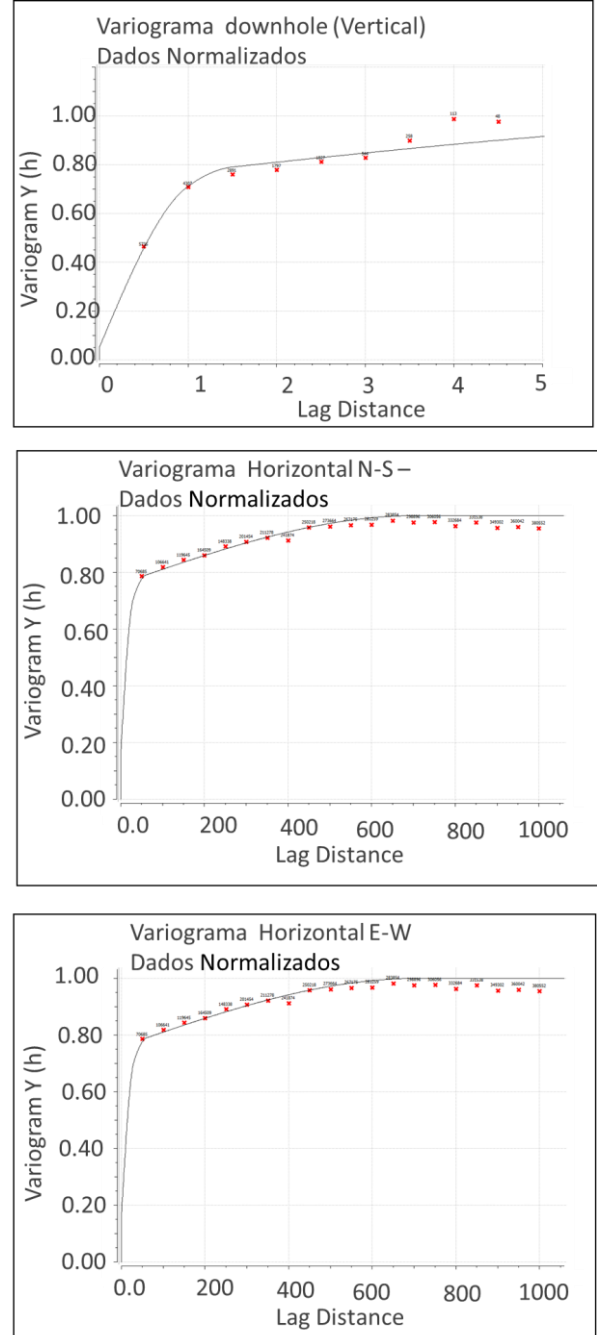


Figura 3-20 – SiO₂ - Variografias dos dados originais

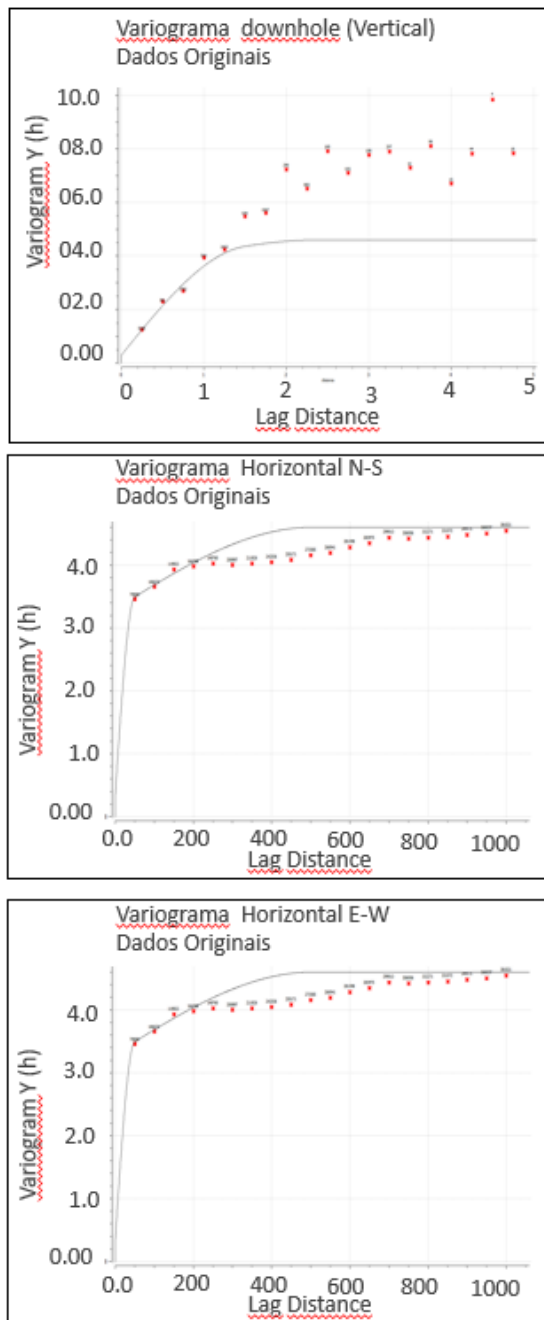
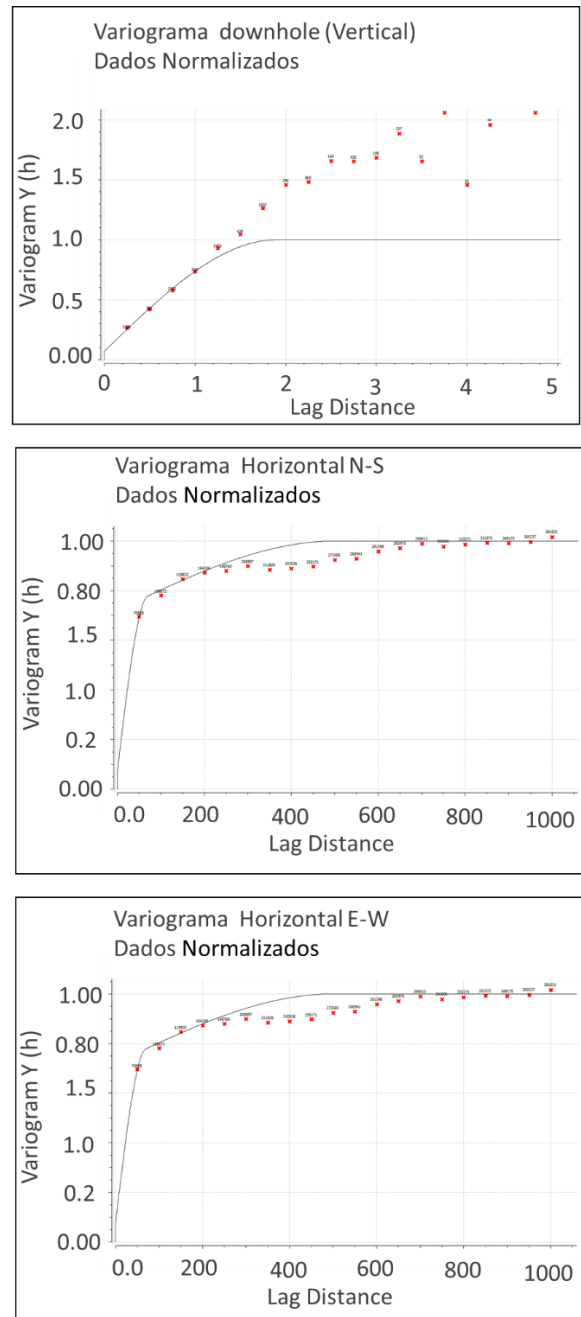


Figura 3-21 – SiO₂ - Variografia dos dados normalizados



3.4 Simulação do modelo

A simulação dos teores de Al_2O_3 e SiO_2 foram realizadas pela simulação sequencial Gaussiana (SGS) (Isaaks, 1990). Para efetuar esses cálculos, foram realizadas as seguintes etapas:

- Definição do modelo de blocos;
- Normalização dos dados usando os pesos do desagrupamento;
- SGS;
- Retro-transformação do grid SGS para o espaço original;
- Validação dos modelos simulados;
 - Checagem dos histogramas;
 - Checagem dos variogramas.

3.4.1 Modelo de blocos

O grid de simulação definido para a SGS possui os seguintes parâmetros (Tabela 3-6):

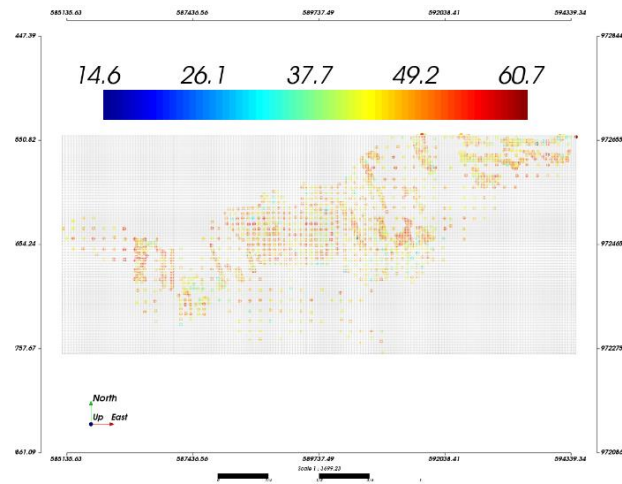
Tabela 3-6 – Parâmetros do Modelo de Blocos

	Número de blocos	Coordenadas utm inferiores	Tamanho dos blocos (m)
x	2000	584743.44	5
y	850	9722532.51	5
z	16	-8.25	0.5

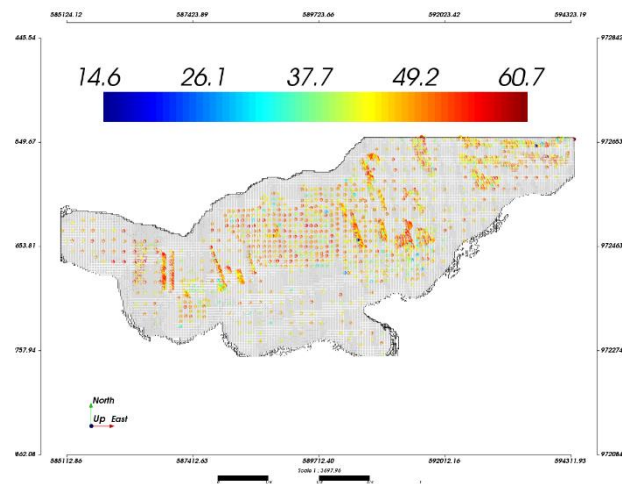
Realizou-se uma estimativa pelo método do vizinho mais próximo das amostras da camada da bauxita maciça, para gerar um modelo expedito da litologia mineralizada com a restrição de 250 m nos eixos x e y de distância média entre as amostras como delimitador dos limites modelo. A restrição de 250 m está relacionada ao espaçamento amostral, que é de 200 x 200 m nas regiões com menor densidade amostral. Esse modelo foi carimbado no modelo de blocos como camada mineralizada e serve de parâmetro de restrição de área para as estimativas (Figura 3-22).

Figura 3-22 – Modelos de blocos dimensionados para as estimativas


A - Modelo de blocos completo e as amostras de Al_2O_3



B - Modelo de blocos com restrição da camada de bauxita maciça e as amostras de Al_2O_3



C - Modelo de blocos com a estimativa da distância entre amostras de bauxita maciça



3.4.2 Normalização dos dados

A SGS tem como hipótese a MultiGaussianidade e os dados seguem, obviamente, uma distribuição normal. Os dados do alvo de estudo foram normalizados usando *nscore* (Deutsch & Journel, 1998) (Figuras 3-23 e 3-24).

Figura 3-23 - Dados de Al₂O₃ Normalizados

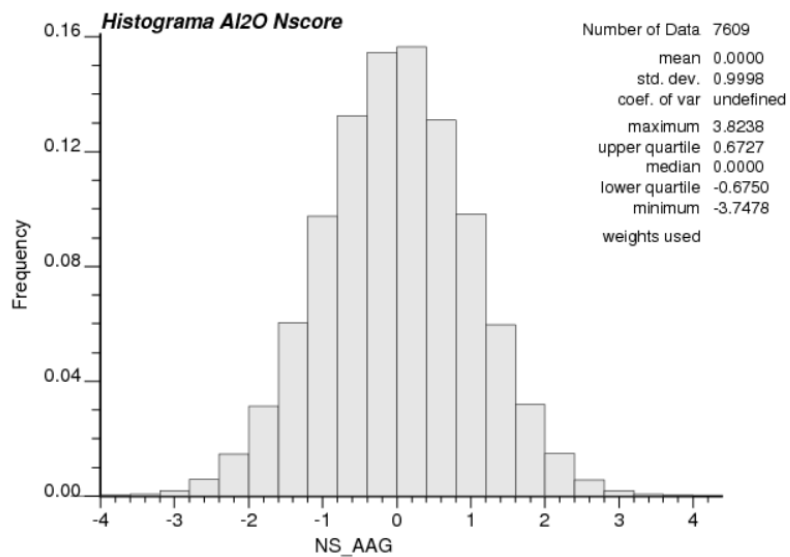
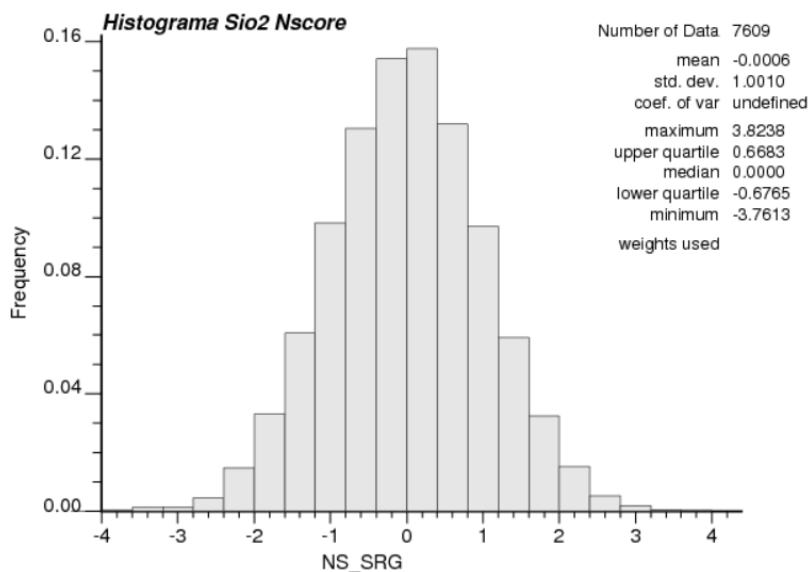


Figura 3-24 - Dados de SiO₂ Normalizados



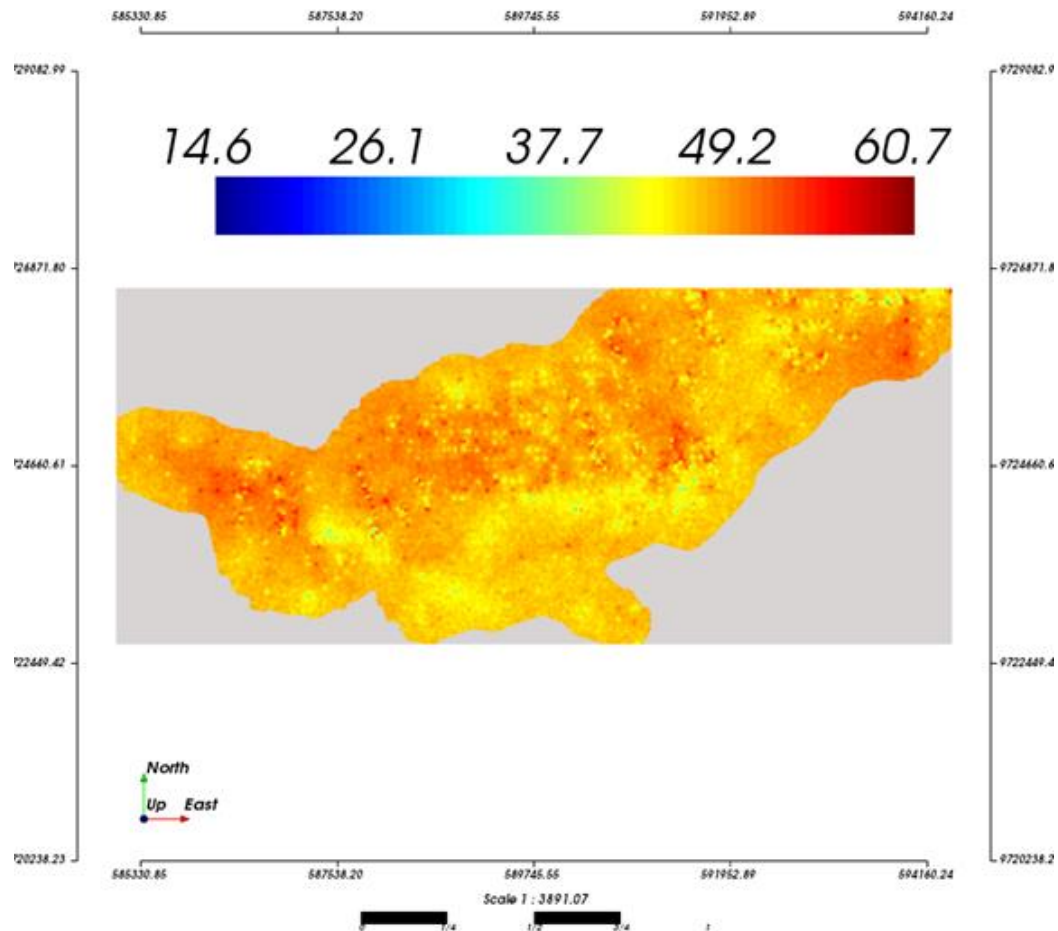
3.4.3 SGS

A simulação sequencial Gaussiana com krigagem simples foi feita com o software *usgsim* (Manchuk & Deutsch, 2012), com 50 simulações. Os parâmetros variográficos e dimensões do grid foram citados anteriormente. Usou-se um raio de busca 1500 m na horizontal, 10 m na vertical, e dip zero. O número máximo de amostras por variável é 48. O número de amostras é um parâmetro importante na SGS. O aumento do número de amostras melhora a reprodução do variograma nas simulações; entretanto, aumenta consideravelmente o tempo de processamento. Após vários testes, constatou-se que o número de 48 amostras tem uma boa reprodução do variograma e faz com que cada uma das simulações seja realizada em 15 minutos, em um computador com a configuração de hardware com processador T(M) i7-2640 CPU @ 2.8GHz, memória RAM 8.00 GB, e Sistema 64-bit Windows 10Pro. Esses parâmetros, dentre vários testadas, foram a que retornou a melhor validação da SGS.

3.4.4 Retro_normalização

As estimativas SGS necessitam realizar o processo reverso da normalização dos dados feita previamente a simulação. Esse processo é realizado utilizando o aplicativo *backtr* (Deutsch & Journel, 1998). A Figura 3-25 apresenta a simulação #1 das 50 interações do Al_2O_3 .

Figura 3-25 - Mapa da simulação #1 de 50 da SGS para Al_2O_3



3.4.5 Validação das realizações

A simulação sequencial Gaussiana deve reproduzir as mesmas características de dispersão dos dados originais, isto é, o histograma e o variograma, sendo dessa forma ditos simulados condicionalmente. Assim uma boa forma de validar as simulações realizadas é conferindo se as flutuações ergódicas dos histogramas e variogramas flutuam em torno dos modelos dos dados originais. Nas Figuras 3-26 a 3-33, atestamos que a simulações realizadas para Al_2O_3 e SiO_2 reproduzem as características dos dados originais, validando as estimativas da SGS.

As Figuras 3-26 e 3-30 mostram nos gráficos que as realizações dos histogramas acumulados da SGS para Al_2O_3 e SiO_2 honraram o histograma acumulado desagrupado dos dados, uma vez que as flutuações ergódicas (curvas

pretas) formadas pelo conjunto de SGS aderem a forma da curva dos dados (vermelha).

As Figuras 3-28, 3-29, 3-32 e 3-33 mostram respectivamente os variogramas verticais e horizontais para Al_2O_3 e SiO_2 . Neste também é verificado, que as realizações SGS honraram a distribuição espacial dos dados, uma vez que o conjunto dos variogramas da SGS formados pelas curvas pretas aderem a forma da curva vermelha que é o variograma dos dados.

As Figuras 3-27 e 3-31 mostram a validação por gráfico de acurácia, ou *accuracy plot* (Pyrzcz & Deutsch, 2014). Essa análise é uma verificação sobre a incerteza local do modelo. A distribuição local é obtida através da validação cruzada. O gráfico de acurácia compara o intervalo de probabilidade contra a verdadeira fração dos valores reais que estão dentro desse intervalo de probabilidade (Pyrzcz & Deutsch, 2014). Para um intervalo de 50% de probabilidade, é esperado que 50% dos valores reais pertençam a este intervalo e quanto mais perto os pontos estiverem da linha de 45° , maior a precisão sobre os valores simulados. Os gráficos de acuracidade da validação da SGS está muito bom, pois os pontos estão próximos da linha $y = x$.

Figura 3-26 - Al₂O₃ - Reprodução dos histogramas das 50 SGSs (preto) e dos dados originais (vermelho)

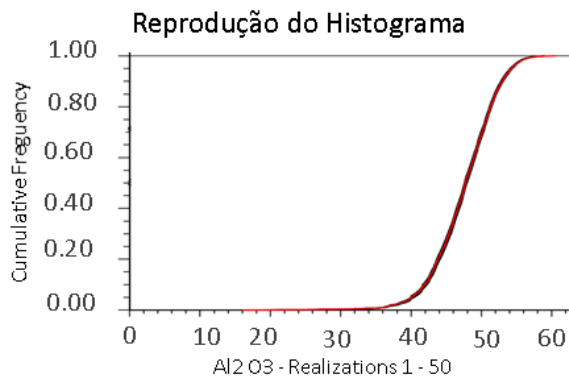


Figura 3-27 - Al₂O₃ - Teste da acuracidade das 50 SGS




Figura 3-28 - Al₂O₃ - Reprodução do variograma horizontal das 50 SGSs (preto) e dos dados originais (vermelho)

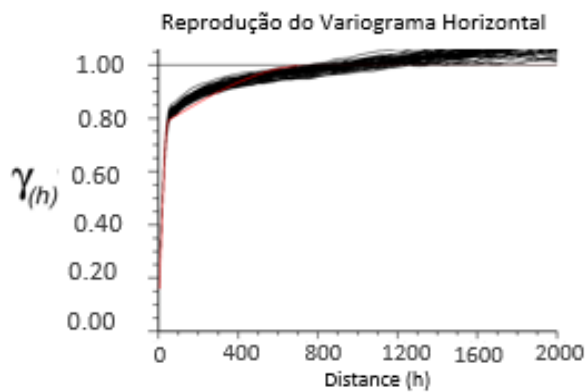


Figura 3-29 - Al₂O₃- Reprodução do variograma vertical das 50 SGSs (preto) e dos dados originais (vermelho)




Figura 3-30 - SiO₂ - Reprodução dos histogramas das 50 SGSs (preto) e dos dados originais (vermelho)



Figura 3-31 - SiO₂ - Teste da acuracidade das 50 SGS




Figura 3-32 - SiO₂ - Reprodução do variograma horizontal das 50 SGSs (preto) e dos dados originais (vermelho)





Figura 3-33 - SiO₂ - Reprodução do variograma vertical das 50 SGSs (preto) e dos dados originais (vermelho)



3.5 Amostragem das n malhas regulares

Com a estimativa da SGS validada, elegeu-se a primeira simulação dentro das 50 como um possível cenário da realidade dos teores do depósito de bauxita.

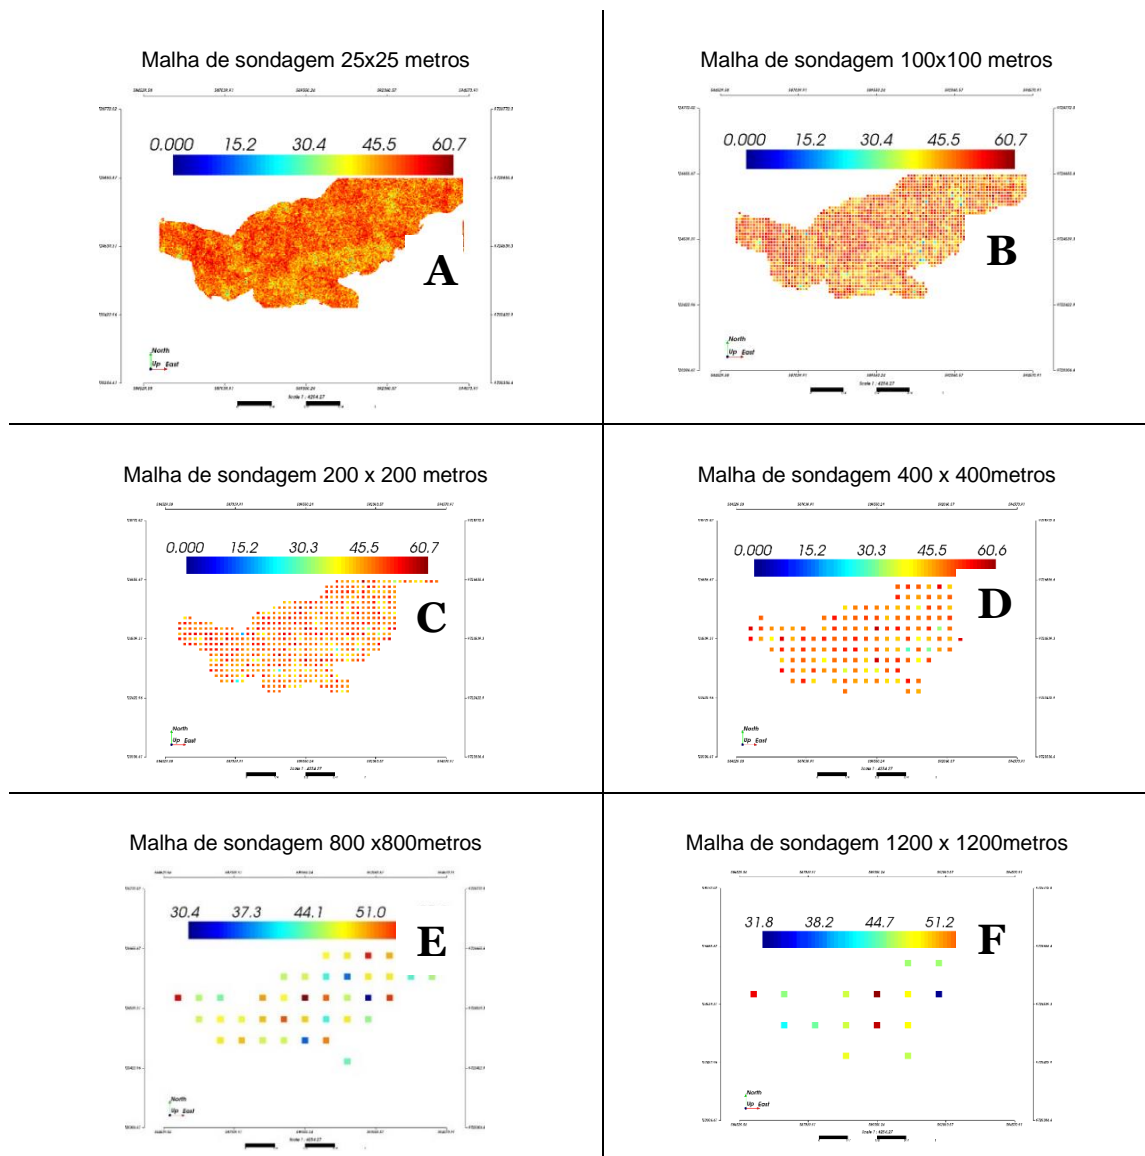
Usando *um script Python* foram amostrados teores de Al₂O₃ e SiO₂ do modelo previamente simulado em malhas regulares em x, y e z conforme a seguintes especificações (Tabela 3-7):

Tabela 3-7 – Parâmetros para amostragem das seis malhas para o estudo proposto

x	y	z	az	dip
25	25	0.5	0	-90
100	100	0.5	0	-90
200	200	0.5	0	-90
400	400	0.5	0	-90
800	800	0.5	0	-90
1200	1200	0.5	0	-90

Cada uma destas seis malhas amostradas compuseram um banco de dados independente conforme ilustrado nos mapas de teores de Al_2O_3 na Figura 3-34.

Figura 3-34 – Malhas de amostragem com distintos espaçamentos (m) – (a) 25x25x0,5, (b) 100x100x0,5, (c) 200x200x0,5, (d) 400x400x0,5, (e) 800x800x0,5 e (f) 1200x1200x0,5



3.6 Simulação usando as malhas regulares amostradas

A mesma estratégia de SGS, usada na elaboração do modelo selecionado como real, foi aplicada a cada um dos seis novos bancos de dados com diferentes espaçamentos de malha amostral realizada no item anterior.

A SGS já foi previamente validada, neste caso, o impacto da diminuição do volume de dados na qualidade dos resultados terá reflexo direto na incerteza da simulação, e isso é o objeto de estudo que será abordado nos capítulos a seguir.

3.6.1 Retro-normalização

As estimativas SGS necessitam realizar o processo reverso da normalização dos dados feita previamente a simulação. Esse processo é realizado utilizando backtr (ref) (Deutsch & Journel, 1998).

3.6.2 Reblocagem dos blocos

As simulações SGS foram realizadas em blocos de dimensões de 5x5x0.5 m, para todas as seis malhas com diferentes espaçamentos (Figura 3-34). As simulações SGS com cada uma das seis malhas foram reblocadas para o suporte de dimensões 25x25x0.5 metros.

3.7 Sumarização das incertezas

3.7.1 Curva teor tonelagem das simulações

Curvas de parametrização teor-tonelagem foram geradas para cada um dos seis conjuntos de simulações realizados de Al_2O_3 e SiO_2 com malhas amostrais distintas, conforme Figuras 3-35 e 3-36.

Figura 3-35 – Curvas de parametrização teor-tonelagem de Al_2O_3 para as malhas com distintos espaçamentos simulados 50 cenários para cada.

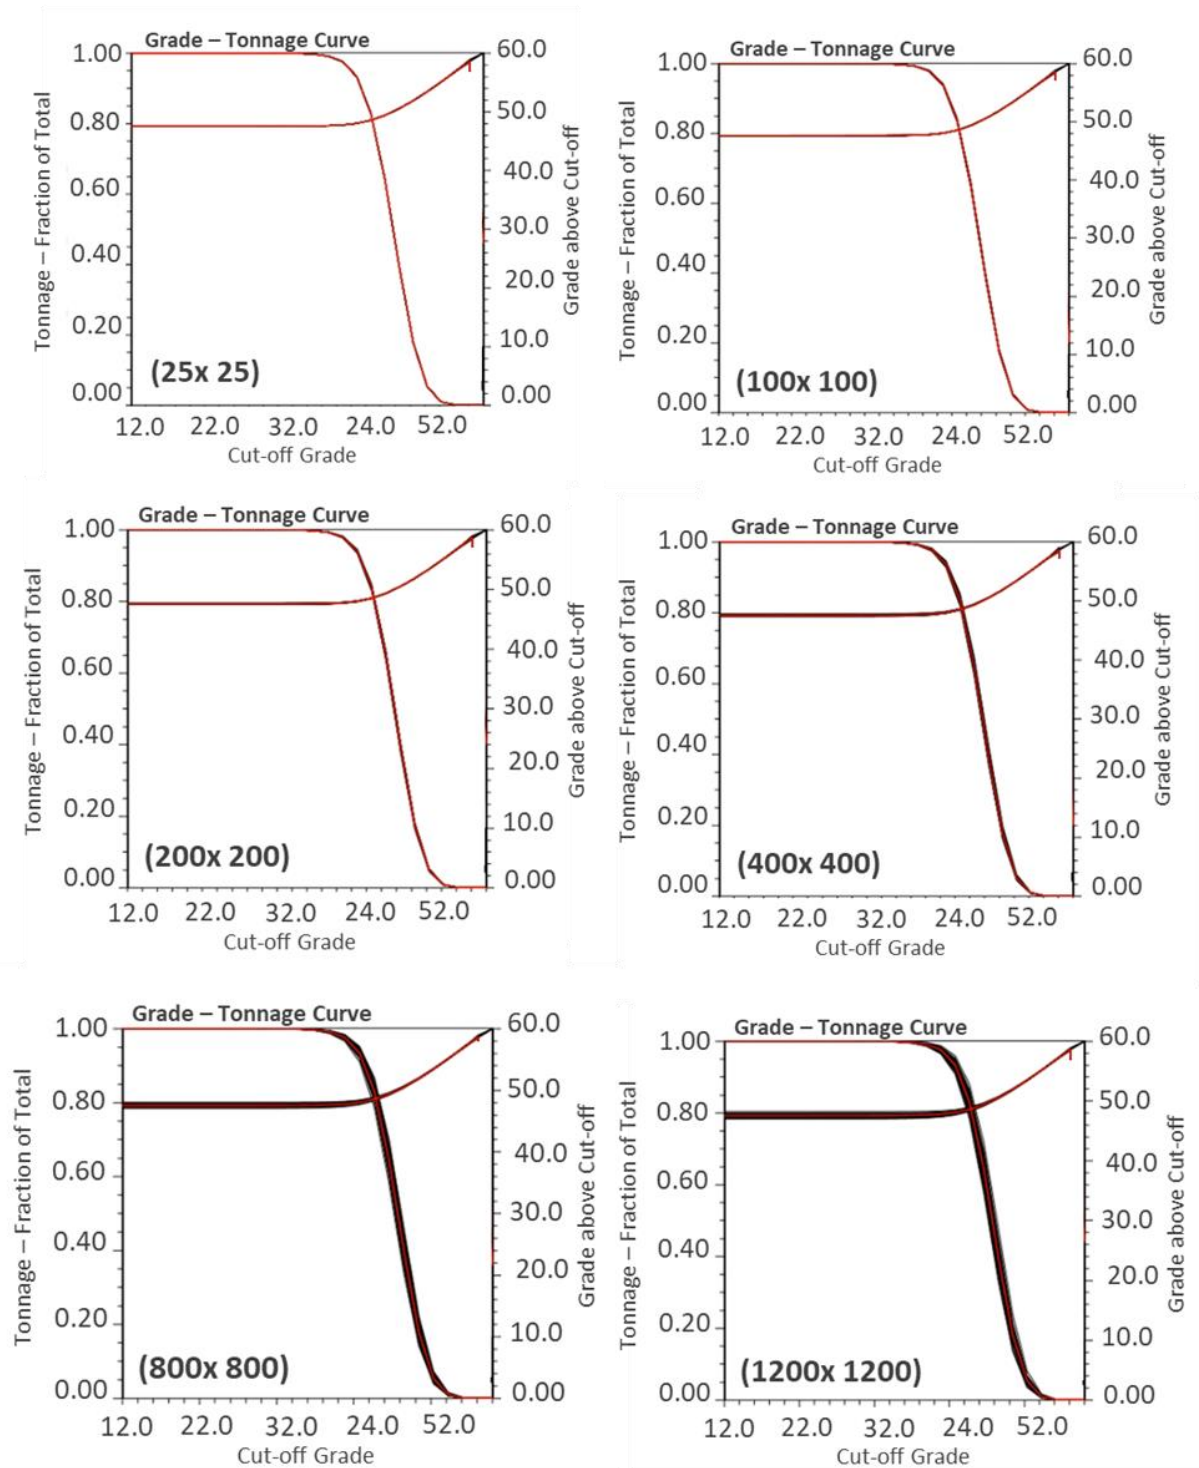
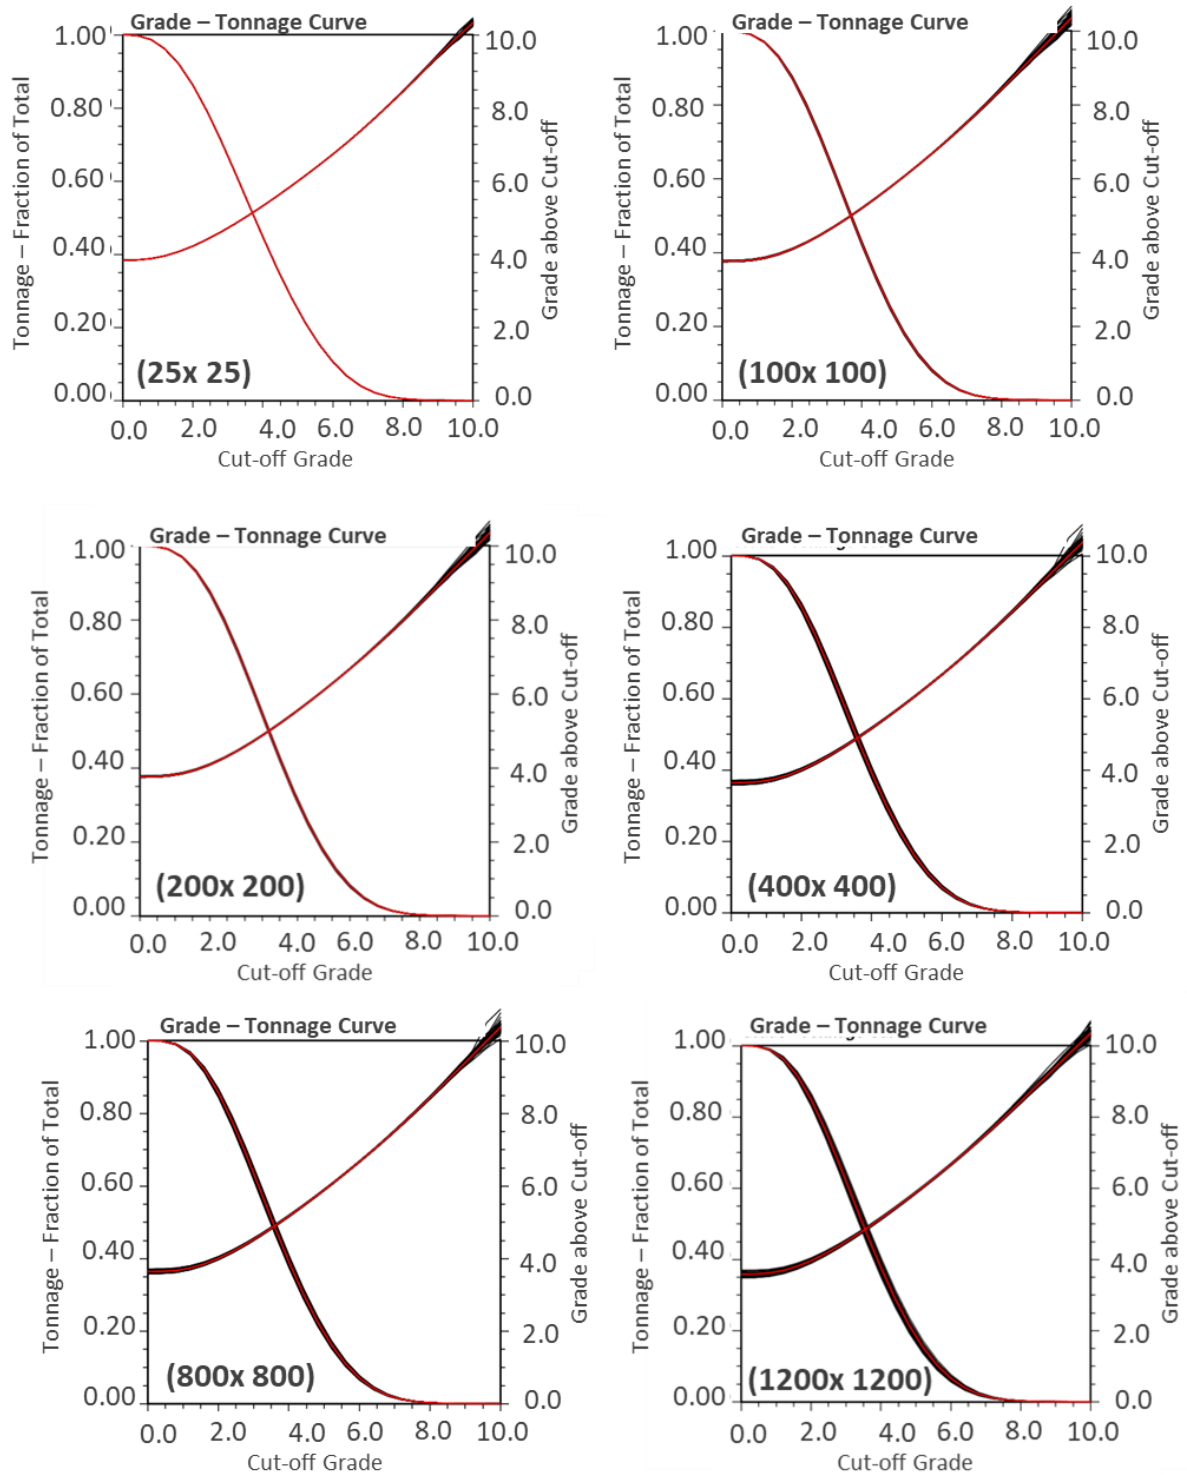


Figura 3-36 – Curvas de parametrização teor-tonelagem de SiO₂ para as malhas com distintos espaçamentos simulados 50 cenários para cada.



A largura da banda formada pela propagação das curvas de tonelagem é uma medida qualitativa da incerteza associada aos recursos minerais. Assim, quanto mais estreita a banda formada pela dispersão dessas curvas, menor é a incerteza; por sua vez, quanto maior a banda, maior é a incerteza.

O primeiro produto desse estudo de caso foi a geração das curvas de parametrização teor-tonelagem por meio de 50 realizações para os seis bancos de dados com diferentes espaçamentos amostrais. As Figuras 3-35 e 3-36 apresentam as curvas de parametrização de Al_2O_3 e SiO_2 obtidas com os diferentes espaçamentos de dados. Analisando esses gráficos, é notório que quanto mais denso for o espaçamento dos dados na malha de amostragem, menor é a espessura da banda de espalhamento formadas pelas curvas;

Isso mostra qualitativamente que a incerteza relativa aos recursos minerais é inversamente proporcional à densidade de amostragem.

O teor de corte é o teor mínimo exigido para que um mineral ou metal seja minerado (e processado) economicamente. O material encontrado acima desse teor é considerado minério, enquanto o material abaixo desse teor é considerado estéril. Ao definir um limite de valor na curva de teor e tonelagem, obtém-se o valor da tonelagem e o teor médio para o material acima desse limite. Assim, é possível identificar de forma quantitativa o grau de incerteza proveniente das simulações de recursos.

As Figuras 3-37 e 3-38 mostram através do gráfico *boxplot* a distribuição dos valores da tonelagem (expressa como fração do total da massa do depósito) considerando o teor de corte de Al_2O_3 de 46% e o teor de corte de SiO_2 de 4.4%. Quanto maior o espaçamento da malha de amostragem, maior é o espalhamento ou largura dos *boxplots*, que representa a incerteza associada a quantidade de minério (tonelagem).

Várias medidas são usadas para quantificar essa incerteza. Podem ser usadas medidas de incerteza absoluta como por exemplo, desvio padrão, coeficiente de variação, diferença entres os percentis 90 (P90) e 10 (P10), incerteza relativa $(P90 - P10) / P50$ (Deutsch *et al.*, 2007) e MME (Erro Máximo Estimado, $[(P95_{(i)} - P5_{(i)})/2]/E_{type(i)}$) (Kopper *et al.*, 2017).

Figura 3-37 – Gráfico box-plot do valor da massa (% da massa total) de Al_2O_3 das 50 SGS para cada malha estudada para o teor de corte 46%.

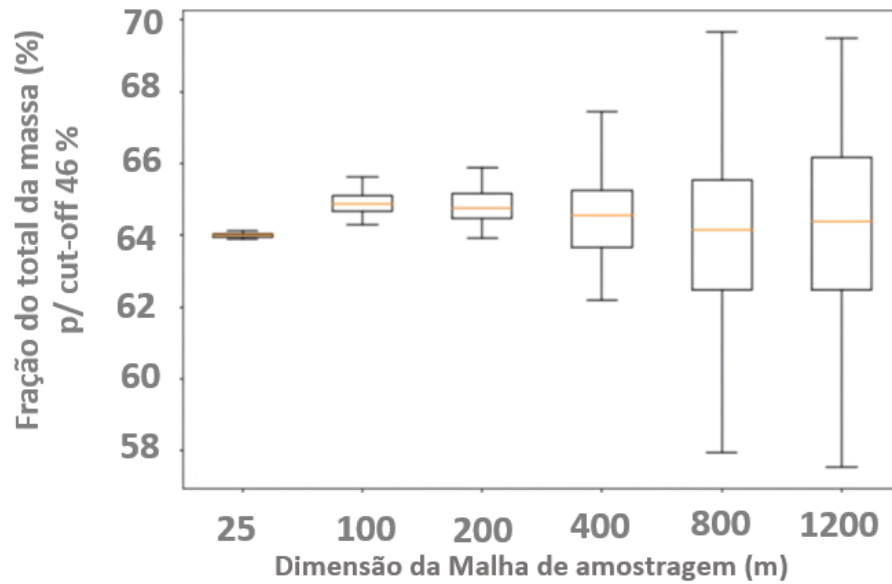
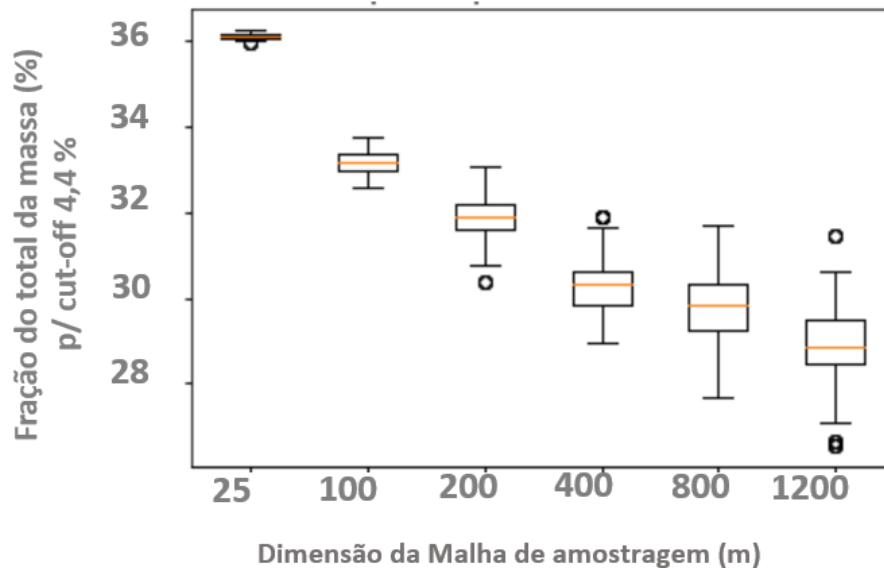


Figura 3-38 - Gráfico box-plot do valor da massa (% da massa total) de SiO_2 das 50 SGS para cada malha estudada para o teor de corte 4.4%.



Por exemplo, considere a distribuição da tonelagem acima do teor de corte de 46% de Al_2O_3 para a malha de 25x25x0,5 m (boxplot mais da esquerda da figura 3-37). O P90 dessa distribuição é 64,10% e P10 é 63,90%. A diferença entre o P90 e P10 é 0,20%, esse valor mensura a incerteza das massas estimadas. Essa medida foi usada para mensurar a incerteza da tonelagem e do teor médio global para todas as malhas.

Assim, considerando o teor de corte de Al_2O_3 de 46% e adotando a diferença entre o P10 e o P90 como a medida da incerteza no limite de confiança de 80%, obtemos a medida da incerteza da massa estimada de bauxita associada aos diferentes espaçamentos de dados (i) 25x25x0,5; (ii) 100x100x0,5; (iii) 200x200x0,5; (iv) 400x400x0,5; (v) 800x800x0,5 e (vi) 1200x1200x0,5. Respectivamente, a incerteza obtida foi de 0,20%, 0,75%, 1,63%, 2,63%, 4,50% e 6,50% (Figura 3-39).

Da mesma forma na Figura 3-40, temos respectivamente a incerteza obtida para a fração do total da massa de SiO_2 com teor de corte 4,4% de 0,13%, 0,64%, 1,21%, 1,5%, 1,87% e 1,97%.

A incerteza obtida para o teor médio do Al_2O_3 com teor de corte 46% nessas malhas é: 0,008%, 0,033%, 0,051%, 0,111%, 0,234% e 0,247% (Figura 3-41). Para o teor médio da SiO_2 , com teor de corte 4,4% temos a incerteza para as malhas estudadas de: 0,007%, 0,016%, 0,024%, 0,027%, 0,030% e 0,050% (Figura 3-42). Esses resultados mensuram o aumento da incerteza à medida que o espaçamento dos dados aumenta.

Como verificado, uma característica deste minério de bauxita é uma baixa variação no teor médio de Al_2O_3 e SiO_2 para estimativas globais.

Figura 3-39 – Incerteza da massa de Al_2O_3 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 46%.




Figura 3-40 - Incerteza da massa de SiO_2 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 4,4%.




Figura 3-41 - Incerteza do teor médio de Al_2O_3 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 46%.





Figura 3-42 - Incerteza do teor médio de SiO_2 perante diferentes espaçamentos de malhas de amostragem para o teor de corte 4,4%.



3.7.2 Classificação de Recursos

3.7.2.1 SGS

Considerando apenas os aspectos relacionados às estimativas da simulação geoestatística, a classificação dos recursos minerais é realizada mensurando a dispersão ao redor do teor estimado. Uma prática na indústria (Verly *et al.*, 2014) é classificar como recursos medidos os volumes de produção trimestrais ou mensais para os quais se prevê que a precisão esteja dentro do intervalo de mais ou menos 15% do teor médio estimado em 90% do tempo; e classificar como recursos inferidos os volumes anuais de produção onde o teor estará dentro de 15% do teor médio previsto 90% do tempo.

A faixa de precisão ao redor do teor médio previsto em 90% do tempo é uma medida que varia de acordo com as necessidades comerciais da mina, do bem mineral, bem como da habilidade do profissional qualificado pelos estudos do projeto em definir com justificativa plausíveis para esse valor, como demonstrado por Silva & Boisvert (2014) na análise de diferentes parâmetros de precisão e acurácia na classificação de recursos.

A capacidade de produção da atividade minerária do alvo de estudo é 3,7 Mt por ano, o que representada uma produção mensal de 307 kt, equivalente à produção de 0,9 Mt no trimestre, considerando uma densidade de 1.47 g/cm³, esses valores de massas de produção trimestral e anual equivalem a painéis de produção de dimensões de 560x560x2 e 1120x112x2 m respectivamente.

A metodologia para classificação dos recursos de Al₂O₃ e SiO₂ para cada uma das seis malhas simuladas com base nas SGS foi:

- Os modelos simulados com SGS, suporte de 5x5x0.5, foram reblocados para o suporte do volume da produção trimestral;
- Os modelos simulados com SGS, suporte de 5x5x0.5, foram reblocados para o suporte do volume da produção anual;
- Cálculo do E-type dos teores das simulações;
- Cálculo da probabilidade do teor de cada bloco estar 15% ao redor da média com suporte da produção trimestral;
- Cálculo da probabilidade do teor de cada bloco estar 15% ao redor da média com suporte da produção anual;
- Os blocos com valores +/- 15% ao redor da média com suporte do

volume trimestral e com 80% de confiança, define os blocos de Recurso Medido;

- Os blocos com valores de +/- 15% ao redor da média com suporte do volume anual, com 80% de confiança, define os blocos de Recurso Indicado.

A proporção de blocos cujos valores de Al_2O_3 e SiO_2 estarem +/- 15% ao redor do teor médio com 90% de confiança na escala de produção trimestral e anual obtidas para os diferentes espaçamentos de dados: (i) 25x25x0,5; (ii) 100x100x0,5; (iii) 200x200x0,5; (iv) 400x400x0,5; (v) 800x800x0,5 e (vi) 1200x1200x0,5 é, respectivamente (Figuras 3.40 e 3.41):

- 99.75%, 99.2%, 99.2%, 97.35%, 99.2% e 98.7% (Al_2O_3 – prod. trimestral – incerteza recurso medido);
- 99.2%, 98.4%, 99.2%, 97.5%, 98.4% e 98.4% (Al_2O_3 – prod. anual – incerteza recurso indicado);
- 98.5%, 88%, 74%, 38%, 10% e 10% (SiO_2 – prod. trimestral – incerteza recurso medido);
- 96.6%, 85%, 81%, 74%, 65% e 61% (SiO_2 – prod. anual – incerteza recurso indicado).

Figura 3-43 – Proporção de blocos com valores de Al_2O_3 estarem +/- 15% da média c / 90% confiança para as massas de ROM referente ao período trimestral, (recurso medido) e período anual (recurso indicado)





Figura 3-44 Proporção de blocos com valores de SiO_2 estarem +/- 15% da média c / 90% confiança para as massas de ROM referente ao período trimestral, (recurso medido) e período anual (recurso indicado)



A classificação dos recursos usando SGS para Al_2O_3 demonstra, que para 95% do volume do depósito, considerando uma tolerância de +/- 15% ao redor da média com 80% de confiança, a possibilidade de se definir uma malha de amostragem com até 800 m de espaçamento para classificar os recursos como medidos. Um espaçamento enorme assim, é justificado pelo fato de a média do Al_2O_3 variar muito pouco, como mostrado pelo seu coeficiente de variação e desvio padrão.

No entanto, para classificar adequadamente o depósito de bauxita se faz necessário se levar em consideração os elementos deletérios que definem parâmetros para definição e aproveitamento do minério. Neste caso de estudo, levamos em consideração apenas o SiO_2 .

A classificação dos recursos com SGS para SiO_2 demonstra pelo gráfico na Figura 3-41 que para 80% do volume do depósito, considerando uma tolerância de 15% ao redor da média com 90% de confiança, uma malha de amostragem de 150 m define recursos medidos e uma malha de amostragem de 200 metros define os recursos indicados.

Modelou-se no software Leapfrog, versão 5.0, três sólidos considerando as distancias entres os furos de sondagem amostrados:

- Até 150 m, para recursos medido;
- Entre 150 e 200 m, para recursos indicados;
- E distancias maiores que 200 m, para recursos inferidos.

Esses sólidos foram carimbados no modelo de blocos e então se definiu o modelo com a classificação de recursos a ser declarado conforme Tabela 3-8 e Figura 3-42.

No estudo da incerteza associado a diferentes tamanhos de malhas, foi observado no resultado das curvas teor-tonelagem as incertezas relativas ao teor médio e massa de SiO_2 e Al_2O_3 . Essa incerteza é atribuída aos resultados da tabela de recursos (Tabela 3-8).

Figura 3-45 - Mapa da Classificação de Recursos Minerais do Depósito de Bauxita, (Recurso Medido - em vermelho, Recurso Indicado - em Amarelo, Recurso Inferido - em Azul, Collar dos furos - pontos pretos)

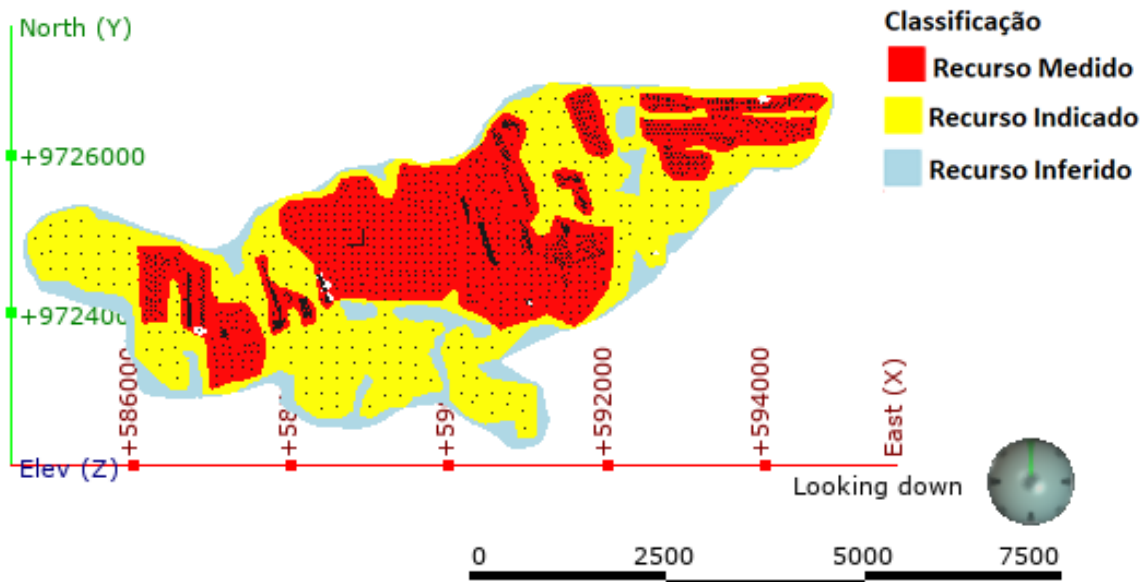


Tabela 3-8 - Classificação de Recursos do Depósito de Bauxita

Relatório de Recursos						
Cut-off: não usado						
Classificação	Densidade g/cm ³	Tonnes Mt	Teor Médio		Incerteza Teor Médio	
			Al ₂ O ₃ %	SiO ₂ %	Al ₂ O ₃ %	SiO ₂ %
INDICADO	1.47	264	47.10	5.44	0.03	0.02
MEDIDO	1.47	222	47.88	4.83	0.05	0.03
MEDIDO + INDICADO	1.47	486	47.45	5.16	0.04	0.03
INFERIDO	1.47	43	46.51	5.34	-	-

4 Conclusões

O estudo de caso desta dissertação de mestrado verificou que a densidade amostral afeta diretamente a incerteza associada aos cálculos dos recursos minerais.

As curvas de parametrização teor-tonelagem foram geradas com os resultados das 50 simulações sequenciais Gaussianas (SGS) das variáveis Al_2O_3 e SiO_2 para cada espaçamento amostral com malhas de dimensões 25x25; 100x100; 200x200; 400 x 400; 800x800 e 1200x1200 metros ao longo das direções X e Y. Esses resultados confirmam que a incerteza associada as estimativas dos recursos minerais são de forma não linear proporcionalmente maiores à medida que as dimensões das malhas aumentam.

Para os parâmetros da SGS usados e aplicando um teor de corte de 46% para Al_2O_3 há uma variação no teor médio global de 0,008%, 0,033%, 0,051%, 0,111%, 0,234% e 0,247% e na massa de 0,20%, 0,75%, 1,63%, 2,63%, 4,50% e 6,50%, respectivamente para as malhas 100x100; 200x200; 400x400; 800x800 e 1200x1200 metros. Para a SiO_2 , com teor de corte 4,4% a variação no teor médio global é 0,007%, 0,016%, 0,024%, 0,027%, 0,030% e 0,050% e a massa de 4.4%: 0,13%, 0,64%, 1,21%, 1,5%, 1,87% e 1,97%.

É aconselhado ao gestor do projeto considerar essa incerteza ao aplicar os valores de teor médio e massa em seu gerenciamento, como por exemplo o fluxo de caixa do projeto. As dimensões das malhas de amostragem podem ser avaliadas pelo gestor considerando se elas estão abaixo ou acima do risco máximo admitido pelo empreendimento em questão.

A incerteza dos teores foi avaliada observando a sensibilidade dos teores de um volume que representa a produção trimestral e de um volume que representa a produção anual redor do teor global para os recursos indicados e medidos.

No caso desse depósito de bauxita, o teor de Al_2O_3 apresenta uma incerteza em volume e teor médio globais baixas, a incertezas locais também são baixas e permitem previsões confortáveis para a lavra, suportando espaçamentos amostrais até 800 metros.

O teor de SiO_2 apresenta uma incerteza global baixa, porém possui uma incerteza local alta em seus teores médios por bloco estimado. Para os trabalhos de previsão do teor médio da lavra seja satisfatório, exige malhas de adensamento

amostral de até 150 metros para recursos medidos e 200 metros para recursos indicados.

No caso deste depósito de bauxita, a classificação de seus recursos minerais foi realizada considerando a incerteza dos teores locais da SiO_2 . Ficando assim, definido como recursos medidos as regiões com influência de amostras até 150 metros; recursos indicados as regiões com influência de amostras de 150 até 200 metros e recursos inferidos as regiões com influência de amostras maiores que 200 metros.

Cada tipo de depósito mineral estudado tem suas características intrínsecas. A quantificação da incerteza dos recursos minerais ajuda a tomar melhores decisões de negócios. Por exemplo, se a empresa de mineração quiser evitar riscos, pode preferir investir em projetos com pouca incerteza avaliando o seu projeto com metodologias similares as discutidas nesta dissertação.

É desejado que em trabalhos futuros, após essa dissertação, que se repita os estudos aqui desenvolvidos em depósitos minerais com maiores incertezas globais como Au e Cu. Também é desejado que se desenvolva a mesma metodologia para a simulação das bandas rotativas e comparar os resultados com a simulação sequencial Gaussiana em termos das incertezas e classificação obtidas, e também no quesito tempo de realização das operações.

5 Bibliografia

ABZALOV, M. Applied Mining Geology - Modern Approaches in Solid Earth Sciences Book 12. *Springer International Publishing*, Cham, 448p, 2016.

BONATO, F. S.; COSTA, J. F. C. L.; & KOPPE, J. C. Geostatistical Simulation: A Framework to Forecast Fluctuations During Mining. *Proc. 9th Intern. Symp. Mine Planning and Equipment Selection*, Rotterdam, Balkema, p. 167-172, 2000.

BOUCHER, A.; DIMITRAKOPOULOS, R.; & VARGAS-GUZMAN, J. A. Joint Simulation, Optimal Drillhole Spacing and the Role of the Stockpile. *Leuangthong O, Deutsch C (eds) Geostatistics Banff 2004 - Quantitative Geology and Geostatistics*, Springer, Dordrecht, v. 14, p. 35-44, 2005.

CBRR. Guia CBRR Para Declaração de Resultados de Exploração, Recursos e Reservas Minerais. *Comissão Brasileira de Recursos e Reservas*, 54p, 2016. Disponível em <http://www.cbrr.org.br/docs/guia_declaracao.pdf> Arquivo capturado em janeiro de 2019.

CRIRSCO. International Reporting Template for the Public Reporting of Exploration Targets, Exploration Results, Mineral Resources and Mineral Reserves. *The Committee for Mineral Reserves International Reporting Standards*, 79p, 2019. Disponível em <http://www.criusco.com/templates/CRIRSCO_International_Reporting_Template_November_2019.pdf> Arquivo capturado em Novembro de 2019.

DAGBERT, M., DAVID, M., CROZEL, D., DESBARATS, A. Computing variograms in folded strata-controlled deposits. In: VERLY, G. et al. (Ed.). *Geostatistics for Natural Resources Characterization*. D. Reidel, Dordrecht, p. 71-89. 1984.

DEUTSCH, C. V.; & BEARDOW, A. P. Optimal Drillhole Spacing for Oil Sands Delineation. *CIM Annual Meeting*, Calgary, Alberta, 1999.

DEUTSCH, C. V. DECLUS: A Fortran 77 Program for Determining Optimum Spatial Declustering Weights. *Computers & Geosciences*, v. 15(3), p. 325-332, 1989.

DEUTSCH, C. V.; & JOURNEL, A. G. GSLIB: Geostatistical Software Library and User's Guide. *Oxford University Press*, New York, 369p, 1998.

DEUTSCH, C. V.; LEUANGTHONG, O; & ORTIZ, J. M. Case for Geometric Criteria in Resources and Reserves Classification. *Transactions-society for Mining Metallurgy and Exploration Incorporated*, v. 322, p. 1-11, 2007.

DOHM, C. Quantifiable Mineral Resource Classification: A Logical Approach. *Leuangthong O, Deutsch C (eds) Geostatistics Banff 2004 - Quantitative Geology and Geostatistics*, Springer, Dordrecht, v. 14, p. 333-342, 2005.

DRUMOND, D. A.; AMARANTE, F. A. N.; KOPPE, V. C.; & Costa, J. F. C. L. A Chart for Judging Optimal Sample Spacing for Ore Grade Estimation: Part II. *Natural Resources Research*, v.26, p. 191-199, 2019.

EMERY, X., HERNANDEZ, J., CORVALAN, P., & MONTANER, D. Developing a Cost-effective Sampling Design for Forest Inventory. In J. M. Ortiz, & X. Emery (Eds.), *Proceedings of the Eighth International Geostatistics Congress, Gecamin*, v. 2, p. 1001–1010, 2008.

ENGLUND, E. J.; & HERAVI, N. Conditional Simulation: Practical Application for Sampling Design Optimization. *Soares A. (eds) Geostatistics Tróia '92 Quantitative Geology and Geostatistics*, Springer, Dordrecht, v. 5 p. 613-624, 1993.

GOOVAERTS, P. Geostatistics for Natural Resources Evaluation. *Oxford University Press*, New York. 496p, 1997.

GOOVAERTS, P. Geostatistical modelling of uncertainty in soil science. *Geoderma*, 103, 3–26, 2001.

ISAAKS, H. E. The application of Monte Carlo Methods to the Analysis of Spatially Correlated Data. (Tese Doutorado), *Stanford University*, Stanford, 213p, 1990.

ISAAKS, H. E.; & SRIVASTAVA, M. R. An Introduction to Applied Geostatistics, *Oxford University Press*. New York, 561p, 1989.

JOURNEL, A. G. Geostatistics for Conditional Simulation of Ore Bodies, *Economic Geology*, v. 69(5), p. 673-687, 1974.

JOURNEL, A. G. Nonparametric Estimation of Spatial Distributions. *Journal of the International Association for Mathematical Geology*, v. 15(3), p. 445-468, 1983.

JOURNEL, A. G. The Lognormal Approach to Predicting Local Distributions of Selective Mining Unit Grades. *Journal of the International Association for Mathematical Geology*, v. 12(4), p. 285-303, 1980.

JOURNEL, A. G.; & KYRIAKIDIS, P. C. Evaluation of Mineral Reserves. *Oxford University Press*, New York, 232p, 2004.

LO-US200KRIGE, D. G. A Statistical Approaches to Some Basic Mine Valuation Problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, v. 52, p. 119-139, 1951.

KOPPE, V. C.; COSTA, J. C. A; & KOPPE, J. C. Coordenadas Cartesianas x Coordenadas Geológicas em Geoestatística: Aplicação à Variável Vagariosidade Obtida por Perfilagem Acústica. *REM - Revista Escola de Minas*, Ouro Preto, v.59(1), p. 25-30, 2006.

KOPPE, V. C. Metodologia para Comparar a Eficiência de Alternativas para 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*, Porto Alegre, 215p, 2009.

KOPPE, V. C., COSTA, J. F. C. L., PERONI, R. L., & KOPPE, J. C. Choosing between two kind of

sampling patterns using geostatistical simulation: Regularly spaced or at high uncertainty locations? *Natural Resources Research*, 20(2), 131–142, 2011.

KOPPE, V. C.; RUBIO, R. H.; & COSTA, J. C. A Chart for Judging Optimal Sample Spacing for Ore Grade Estimation. *Natural Resources Research*, v. 26, p. 191–199, 2017.

LAGE, N. M. Aproveitamento do Rejeito da Bauxita da Mina de Juriti por Flotação. (Graduação em Engenharia de Minas), *Escola de Minas, Universidade Federal de Ouro Preto*, Ouro Preto, 35p, 2018.

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

MCARTHUR, G. J. Using Geology to Control Geostatistics in the Hellyer Deposit. *Mathematical Geology*, v. 20(4), p. 343-366. 1988.

MANCHUK, J. G.; & DEUTSCH, C. V. A Flexible Sequential Gaussian Simulation Program: USGSIM. *Computers & Geosciences*, v. 41, p. 208-216, 2012.

MATHERON, G. Principles of Geostatistics, *Economic Geology*, v. 58(8), p. 1246-1266, 1963.

MATHERON, G. Les Variables Régionalisées et Leur Estimation: Une Application de la Théorie des Fonctions Aléatoires Aux Sciences de la Nature. (Tese Doutorado), *Masson et CIE*, Paris, 1965.

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

PATTERSON, S. H. Bauxite Reserves and Potential Aluminum Resources of the World. *United States of American: Geological Survey Bulletin*, v. 1228, 176p, 1967.

PILGER, G. G. Critérios para Locação Amostral Baseados em Simulação Estocástica. (Dissertação de Mestrado), *Universidade Federal do Rio Grande do Sul*, Porto Alegre, 127p, 2000.

PILGER, G. G.; COSTA, J. F. C. L.; & KOPPE, J. C. Additional Samples: Where they Should be Located. *Natural Resources Research*, v. 10(3), p. 197-207, 2001.

PILGER, G. G.; COSTA, J. F. C. L.; & KOPPE, J. C. Optimizing the Value of a Sample. *APCOM 2002: 30th International Symposium on the Application of Computers and Operations Research in the Mineral Industry*, p. 85-94, 2002.

PYRCZ, M. J.; & DEUTSCH, C. V. Geostatistical Reservoir Modeling. *Oxford University Press*, 448p, 2014.

REMY, N.; BOUCHER, A.; & WU, J. Applied Geostatistics Analysis with SGeMS - A User's Guide. *Cambridge University Press*, p. 169-214, 2011.

RENDU, J. M.; & READDY, L. Geology and the Semivariogram. A Critical Relationship. *APCOM SYMPOSIUM, 17th International Symposium on the Application of Computers and Operations Research in the Mineral Industry*, New York, p. 771-783, 1992.

ROSSI, M. E.; & DEUTSCH, C. V. Mineral Resource Estimation. *Springer Science & Business Media*,

332p, 2014.

RUBIO, H. R.; KOPPE, V. C.; COSTA, J. C.; & CHERCHENEVSK, P. K. How the Use of Stratigraphic Coordinates Improves Grade Estimation. *Rem: Revista Escola de Minas*, v. 68(4), p. 471-477, 2015.

SILVA, D. S. F.; & BOISVERT, J. B. Mineral Resource Classification: A Comparison of New and Existing Techniques. *Journal of the Southern African Institute of Mining and Metallurgy*, v. 114(3), p. 265-273, 2014.

SINCLAIR, A. J.; & BLACKWELL, G. H. Applied Mineral Inventory Estimation. *Cambridge University Press*, Cambridge, 381p, 2004.

SOUZA, L. E. Proposição Geoestatística para Quantificação do Erro em Estimativas de Tonelagens e Teores. (Tese de Doutorado), *Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGEM) - Universidade Federal do Rio Grande do Sul*, Porto Alegre, 188p, 2007.

VERLY, G.; POSTOLSKI, T.; & PARKER H. M. Assessing Uncertainty with Drillhole Spacing Studies: Applications to Mineral Resources, *AusIMM: Orebody Modelling and Strategic Mine Planning Symposium*, Perth, p. 109-118, 2014.

WEBER, K. J. Influence of common sedimentary structures on fluid flow in reservoirs models. *Journal of Petroleum Technology*, v. 34, p. 665-672, 1982.

WEBER, K. J., VAN GEUNS, L. C. Framework for constructing clastic reservoir simulation models. *Journal of Petroleum Technology*, v. 42(10), p. 1248-1253, 1990.

WILDE, B. J. Data Spacing and Uncertainty. (Graduação em Engenharia de Minas), *Department of Civil and Environmental Engineering - University of Alberta*, Edmonton, 103p, 2010.

WILDE, B. J.; & DEUTSCH, C. V. Methodology for Quantifying Uncertainty Versus Data Spacing Applied to the Oil Sands. *CIM Journal*, p. 211-219, 2013.

YAMAMOTO, J. K. Classificação de Recursos Minerais Usando a Variância de Interpolação. *Revista Brasileira de Geociências*, v. 29(3), p. 349-356, 1999.