

UNIVERSIDADE ESTADUAL PAULISTA

Instituto de Geociências e Ciências Exatas

Campus de Rio Claro

**APLICAÇÃO DE REDES NEURAIS NO CONTROLE DE  
TEORES DE COBRE E OURO DO DEPÓSITO DE  
CHAPADA(GO)**

Evandro Cardoso Cintra

Orientador: Prof..Dr. José Ricardo Sturaro

Tese de Doutorado elaborada junto ao  
Curso de Pós-Graduação em Geociências  
- Área de Concentração em Geologia Regional,  
para obtenção do Título de  
Doutor em Geologia

Rio Claro (SP)  
2003

006.32 Cintra, Evandro Cardoso  
C575a Aplicação de redes neurais no controle de teores de cobre e ouro no depósito de Chapada (GO) / Evandro Cardoso Cintra -- Rio Claro : [s.n.], 2003  
170 f. : il., gráfs, tabs.

Tese (doutorado) – Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas  
Orientador: José Ricardo Sturaro

1. Redes neurais (Computação). 2. Retropropagação. I. Título.

Ficha Catalográfica elaborada pela STATI – Biblioteca da UNESP  
Campus de Rio Claro/SP

Comissão Examinadora

---

-Prof. Dr. Tarcísio Barreto Celestino-

---

- Prof. Dr. Jorge Kazuo Yamamoto-

---

- Prof. Dr. Elias Carneiro Daitx-

---

- Prof. Dr. Paulo Milton Barbosa Landim-

---

- Prof. Dr. José Ricardo Sturaro-

---

- Evandro Cardoso Cintra -

Rio Claro, 28 de novembro de 2003

Resultado: Aprovado

*À minha esposa Ana Lúcia,  
e aos meus filhos Gabriel e Victor*

## A G R A D E C I M E N T O S

Ao Prof. Dr. José Ricardo Sturaro, pela orientação e apoio recebidos e, sobretudo pela amizade e compreensão.

À Mineração Maracá S.A, pela cessão dos dados do depósito de Chapada, pelo suporte material e apoio dos colegas de equipe e da direção da empresa, em especial ao Eng<sup>o</sup>. Antenor Silva Jr. pelo estímulo e reconhecimento.

À minha família, pela dedicação e renúncia, em especial aos meus sogros Rubens e Janete pelo apoio aos meus filhos.

## SUMÁRIO

Índice .....	
Índice de Tabelas .....	
Índice de Figuras .....	
Resumo .....	
Abstract .....	
1 - Introdução .....	01
2 – Métodos.....	04
3 – Caracterização da área em estudo.....	42
4 – Histórico e inventário dos dados da exploração mineral.....	74
5 – Aplicação das redes neurais.....	89
6 – Conclusões e sugestões .....	141
7 - Referências bibliográficas .....	144
Apêndice A .....	151

## ÍNDICE

1.	INTRODUÇÃO.....	01
1.1	Objetivos.....	01
1.2	Justificativas.....	02
2.	MÉTODOS.....	04
2.1	Análise estatística descritiva.....	04
2.1.1	Estatística descritiva univariada.....	05
2.1.2	Estatística descritiva bivariada.....	06
2.2	Análise geoestatística.....	08
2.2.1	Análise variográfica.....	09
2.2.2	Krigagem ordinária.....	12
2.3	Redes neurais.....	18
2.4	Treinamento das redes neurais.....	25
2.4.1	Algoritmo de retropropagação do erro em redes MLP.....	27
2.4.2	Algoritmo de Levenberg-Marquardt (LM) em redes MLP.....	31
2.4.3	Validação cruzada.....	32
2.4.4	Regularização bayesiana.....	35
2.5	Aplicações de redes neurais em geologia.....	39
3.	CARACTERIZAÇÃO DA ÁREA EM ESTUDO.....	42
3.1	Localização.....	42
3.2	Clima.....	42
3.3	Relevo.....	44
3.4	Hidrografia.....	44
3.5	Vegetação e solos.....	46
3.6	Geologia regional.....	47
3.6.1	Contexto Geotectônico.....	47
3.6.2	Principais unidades geológicas da área estudada.....	50
3.6.2.1	Terrenos granito-greenstone do norte de Goiás.....	40
3.6.2.2	A Seqüência Mara Rosa.....	52

3.6.2.3	A Seqüência Chapada.....	53
3.6.2.4	A Seqüência Santa Terezinha.....	54
3.6.2.5	Grupo Araxá.....	55
3.6.2.6	Terrenos Granito-Gnáissicos.....	57
3.7	Geologia local.....	57
3.7.1	Geologia do depósito.....	57
3.7.2	Geologia estrutural.....	64
3.7.3	Metamorfismo.....	65
3.7.4	Alterações hidrotermais.....	67
3.7.5	Mineralização e gênese.....	69
4.	HISTÓRICO E INVENTÁRIO DOS DADOS DA EXPLORAÇÃO MINERAL.....	74
4.1	Histórico da exploração mineral e desenvolvimento do depósito de Chapada.....	74
4.2	Método de coleta e integração dos dados.....	80
4.3	Base de dados de sondagem.....	83
4.3.1	Dados geotécnicos.....	83
4.3.2	Dados geológicos.....	84
4.3.3	Dados de análises químicas.....	88
5.	APLICAÇÃO DAS REDES NEURAIS.....	89
5.1	Introdução.....	89
5.2	Conjunto de dados utilizados.....	89
5.2.1	Banco de dados piloto.....	92
5.3	Análise estatística das variáveis.....	94
5.4	Análise geoestatística dos teores de cobre e ouro.....	108
5.5	Modelagem proposta para as redes neurais.....	116
5.6	Apresentação e discussão dos resultados.....	119
5.6.1	Aplicação piloto.....	119
5.6.2	Otimização e aplicação extensiva.....	108
5.6.3	Aplicação em seções de sondagem.....	134
5.6.4	Avaliação da redução de variáveis na rede neural otimizada.....	136

6.	CONCLUSÕES E SUGESTÕES.....	141
7.	REFERÊNCIAS BIBLIOGRÁFICAS.....	144
	APÊNDICE A.....	151
	-Seção de sondagem 1100	
	-Seção de sondagem 2250	
	-Seção de sondagem 3100	
	-Seção de sondagem 3800	

## ÍNDICE DE FIGURAS

Figura	2.1 - Gráfico básico de uma função variograma.....	11
Figura	2.2 - Modelos variográficos.....	11
Figura	2.3 - Modelo de um neurônio artificial . (Haykin, 2001).....	19
Figura	2.4 - Função Limiar, linear e sigmoide.....	21
Figura	2.5 - Rede alimentada adiante (“feedforward”) com uma única camada de neurônios.....	22
Figura	2.6 - Rede alimentada adiante (“feedforward”) com múltiplas camadas.....	23
Figura	2.7 - Rede recorrente sem neurônios ocultos.....	23
Figura	2.8 - Diagrama esquemático da aprendizagem supervisionada.....	27
Figura	2.9 - Diagrama de fluxo de sinal mostrando detalhes do neurônio de saída...	28
Figura	2.10 - Treinamento com regra de parada antecipada baseada na validação cruzada.....	34
	..	
Figura	2.11 - Exemplos de testes de generalização.....	35
Figura	2.12 - Modelo de uma Rede de Função de Base Radial.....	40
Figura	3.1 - Mapa de localização e acesso ao projeto Chapada.....	43
Figura	3.2 - Vista aérea da área do depósito de Chapada.....	45
Figura	3.3 - Mapa de drenagens e arranjo geral do projeto Chapada.....	45
Figura	3.4 - Mapa geológico da província Tocantins.....	48
Figura	3.5 - Mapa geológico do norte de Goiás.....	51
Figura	3.6 - Mapa geológico da Seqüência Santa Terezinha e Grupo Araxá.....	55
Figura	3.7 - Mapa geológico local da Seqüência Chapada.....	59
Figura	3.8 - Bloco diagrama da estratigrafia e macro-estrutura do depósito de Chapada.....	60
Figura	3.9 - Seção geológica transversal (SE-NW) tipo.....	66
Figura	3.10 - Mapa esquemático de alterações hidrotermais.....	68
Figura	3.11 - Calcopirita concordante com a foliação (foto seção polida).....	70
Figura	3.12 - Ouro nativo em contato com calcopirita (foto seção polida).....	71
Figura	3.13 - Associação calcopirita-pirita-magnetita (foto seção polida).....	71

Figura 3.14	- Modelo tridimensional dos corpos mineralizados do depósito de Chapada.....	72
Figura 4.1	- Fluxograma de preparação de amostras de testemunhos de sondagem...	81
Figura 4.2	- Fluxograma de amostragem e controle de qualidade analítica.....	82
Figura 5.1	- Localização dos furos de sondagem utilizados e compartimentação de dados em blocos.....	91
Figura 5.2	- Fluxograma de preparação do banco de dados piloto.....	93
Figura 5.3	- Gráfico de frequência de litologias do conjunto de dados piloto.....	96
Figura 5.4	- Comparativo de distribuição de frequência das variáveis de alteração hidrotermal.....	97
Figura 5.5	- Histogramas de frequência das variáveis de alteração hidrotermal.....	98
Figura 5.6	- Histogramas de frequência das variáveis minerais de minério e teste de normalidade.....	100
Figura 5.7	- Histogramas de frequência das variáveis geotécnicas e teste de normalidade.....	100
Figura 5.8	- Histogramas de frequência das variáveis de concentração metálica.....	102
Figura 5.9	- Gráficos de probabilidade lognormal da distribuição cumulativa dos teores de cobre e ouro.....	103
Figura 5.10	- Gráfico <i>box-plot</i> das variáveis teor de cobre e teor de ouro categorizadas por litologia.....	107
Figura 5.11	- Compartimentação do depósito de Chapada em domínios variográficos.....	110
Figura 5.12	- Orientação dos elipsóides variográficos nas zonas 1, 2 e 3 do corpo principal.....	111
Figura 5.13	- Variogramas direcionais dos teores de ouro no corpo principal (a), no corpo nordeste (b) e fora dos corpos de minério (c).....	113
Figura 5.14	- Variogramas direcionais dos teores de cobre no corpo principal (a), no corpo nordeste (b) e fora dos corpos de minério (c).....	114
Figura 5.15	- Gráfico de probabilidade dos valores amostrados comparados com os valores estimados pela krigagem ordinária.....	115

Figura 5.16	- Vista tridimensional de seção horizontal do modelo de blocos com teores de cobre estimados por krigagem ordinária.....	115
Figura 5.17	- Diagrama da arquitetura da rede neural.....	118
Figura 5.18	- Treinamento com valores extremos.....	120
Figura 5.19	- Gráfico de dispersão de saídas da rede vs. valores reais de teores de ouro e cobre. Redes com valores extremos.....	121
Figura 5.20	- Treinamento de redes neurais sem <i>valores extremos</i> com 30 (a), 22 (b), e 12 (c) neurônios ocultos; e mudança para função logística.....	123
Figura 5.21	- Gráfico de dispersão de saídas da rede vs. valores reais de teores de ouro e cobre. Rede com 30 neurônios ocultos <i>sem</i> valores extremos....	123
Figura 5.22	- Curva de treinamento com variáveis geológicas selecionadas em função da covariância com teores de cobre.....	124
Figura 5.23	- Curva de treinamento sem variáveis geotécnicas.....	125
Figura 5.24	- Teste de generalização nos grupos “2” e “4” .....	126
Figura 5.25	- Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 1.....	128
Figura 5.26	- Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 2.....	129
Figura 5.27	- Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 3.....	129
Figura 5.28	- Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 4.....	129
Figura 5.29	- Teste de generalização de redes treinadas com algoritmo Levenberg-Marquardt.....	131
Figura 5.30	- Teste de generalização de redes treinadas com algoritmo Levenberg-Marquardt e regularização bayesiana.....	133
Figura 5.31	- Teste final de generalização de redes neurais. Gráficos de dispersão dos teores de ouro e cobre nas seções de sondagem 1100 , 2250, 3100 e 3800.....	135
Figura 5.32	- Gráfico de barras mostrando as variáveis de entrada em ordem decrescente segundo os pesos sinápticos de entrada da rede neural.....	137

Figura 5.33 - Gráfico cumulativo do desempenho preditivo da rede neural em função das variáveis de entrada utilizadas na simulação.....	139
Figura 5.34 - Teste de generalização da rede neural do bloco “1” com 10 variáveis de entrada.....	140
Figura 5.35 - Teste de generalização da rede neural do bloco “1” com 5 variáveis de entrada.....	140

## ÍNDICE DE TABELAS

Tabela	4.1	-	Trabalhos de exploração mineral executados entre 1974 e 1989.....	76
Tabela	4.2	-	Programas de sondagem executados no projeto Chapada entre 1976 a 1996	79
Tabela	5.1	-	Subconjuntos de dados por blocos.....	90
Tabela	5.2	-	Variáveis do banco de dados piloto.....	92
Tabela	5.3	-	Estatística descritiva do conjunto de dados piloto.....	95
Tabela	5.4	-	Código de agrupamento de tipos litológicos (“LITHO”).....	96
Tabela	5.5	-	Medidas estatísticas resumo dos teores de cobre e ouro do bloco piloto com e sem valores extremos.....	101
Tabela	5.6	-	Matriz de coeficientes de correlação linear de Pearson .....	105
Tabela	5.7	-	Matriz de coeficientes de correlação linear de Pearson calculados sem valores extremos. (n=6247).....	105
Tabela	5.8	-	Matriz de coeficientes de correlação de Spearman.....	105
Tabela	5.9	-	Correlação linear entre litologia e teores de cobre e ouro .....	106
Tabela	5.10	-	Índices variográficos das diferentes zonas do depósito de Chapada. ....	109
Tabela	5.11	-	Desempenho do treinamento de redes neurais sem valores extremos.....	122
Tabela	5.12	-	Resultados do treinamento de redes neurais com variáveis.....	127
Tabela	5.13	-	Resultados do teste de generalização de redes neurais com variáveis geológicas e coordenadas espaciais utilizando algoritmo LM.....	130
Tabela	5.14	-	Resultados do treinamento de redes neurais com algoritmo.....	132
Tabela	5.15	-	Resultados do teste de generalização de redes neurais com algoritmo Levenberg-Marquardt e regularização Bayesiana.....	132
Tabela	5.16	-	Resultados da simulação de redes neurais nas seções de sondagem.....	134
Tabela	5.17	-	Resultados do desempenho das redes neurais simulando bancadas de 10m..	136
Tabela	5.18	-	Matriz de pesos sinápticos entre a camada de entrada e camada oculta da rede neural otimizada do bloco “1”.....	138

## RESUMO

Este estudo desenvolve a aplicação da técnica de redes neurais artificiais no controle de teor de minério em frentes de lavra a partir de observações geológicas e geotécnicas. A área de estudo da aplicação é o depósito de cobre e ouro de Chapada (Goiás), hospedado por rochas da seqüência vulcano-sedimentar neoproterozóica de Chapada-Mara Rosa. Trata-se de um depósito mineral tipo epigenético, ligado a processos de alteração hidrotermal, associado a zonas estruturalmente favoráveis. As observações geológicas e geotécnicas constituem um banco de dados com 21.212 registros e 21 variáveis, provenientes de amostras de 237 furos de sondagem rotativa diamantada. As variáveis de entrada incluem litologia, porcentagem de sulfetos, razão calcopirita/pirita, frequência de fraturas, RQD, e alterações hidrotermais tais como: cloritização, sericitização, silicificação, epidotização, carbonatização e piritização. As variáveis de saída são: teores de cobre e ouro. O modelo de rede neural utilizado foi o de múltiplas camadas (MLP) alimentada adiante (“feedforward”) totalmente interconectada, com 30 neurônios na camada oculta e 2 neurônios na camada de saída. A rede foi treinada com o algoritmo de retropropagação de Levenberg-Marquardt acoplado com regularização bayesiana. Obteve-se um índice de acertos de 80% na predição de teores de cobre em bancadas simuladas.

**PALAVRAS CHAVE:** Redes neurais, retropropagação, Chapada, cobre, ouro

## ABSTRACT

This study deals with application of artificial neural networks (ANNs) on grade control at mine sites inputting both geological and geotechnical variables. Case study is Chapada copper-gold deposit (Goiás, Brazil), located in the neoproterozoic Chapada-Mara Rosa volcano-sedimentary sequence. Ore is closely related to hydrothermal alteration, structurally controlled. The geological and geotechnical database contain 21,212 records on 21 variables taken from 237 diamond drill holes. Input variables include lithology, sulfide percentage, chalcopyrite/pyrite ratio, fracture frequency, RQD, and hydrothermal alterations such as chloritization, sericitization, silicification, epidotization, carbonatization and pyritization. Output variables are gold and copper grades. Neural network model is feedforward multi-layer perceptron (MLP), fully connected with 30 hidden and 2 output neurons. Network was trained with Levenberg-Marquardt backpropagation algorithm associated with bayesian regularization. Success rate on predicting copper grades on simulated mine benches was over 80%.

**KEYWORDS:** Neural nets, backpropagation, Chapada, copper, gold

# CAPÍTULO 1. INTRODUÇÃO

---

## 1. Introdução

A geologia de modo geral é conhecida como uma ciência “imprecisa” devido ao fato de lidar com fenômenos e materiais complexos produzidos pela natureza. A quantificação de fenômenos naturais tem sido um desafio e uma necessidade crescente especialmente quando relacionados à atividade econômica. A experiência de julgamento e abordagens empíricas são amplamente utilizadas na indústria mineral. Se técnicas de inteligência artificial (IA) puderem fazer uso de conhecimento heurístico ou de técnicas de reconhecimento de padrões, sem exigir do usuário uma alta especialização matemática, elas se tornarão ferramentas ideais para aplicação no campo da geologia de mina. A técnica de redes neurais, como um sistema de IA, tem sido empregada crescentemente na solução de problemas caracterizados por carência ou imprecisão de dados. Embora se constitua um terreno fértil para esse tipo de estudo, o desenvolvimento de aplicações de redes neurais artificiais tem se concentrado no campo da estimativa de reservas, como um método alternativo ou complementar à geoestatística.

### 1.1 Objetivos

Este estudo tem como objetivo desenvolver a aplicação da técnica numérica de redes neurais artificiais na estimativa de teor de minério, a partir de observações geológicas e geotécnicas. Estas observações constituem dados imprecisos e freqüentemente carregados da subjetividade do geólogo ou do técnico que as coleta.

A área de estudo para teste e desenvolvimento da aplicação proposta é o depósito de cobre e ouro de Chapada, localizada no município de Alto Horizonte, estado de Goiás, cujos direitos minerários e dados de projeto são de propriedade da Mineração Maracá S.A, subsidiária da Mineração Santa Elina Indústria e Comércio S.A. As observações geológicas e geotécnicas constituem um banco de dados com 47.000 registros provenientes de 850 furos de sondagem, totalizando 67.000 metros perfurados. Para este estudo foram utilizados 21.212 registros, formando um conjunto considerado representativo das características do depósito de Chapada.

Espera-se demonstrar através deste trabalho, a viabilidade da aplicação da técnica de redes neurais no depósito de Chapada e em outros projetos de mineração. Pretende-se também dar ao leitor uma visão geral do potencial de aplicação de redes neurais em geologia como uma ferramenta de suporte à experiência humana.

Em síntese, mira-se na direção de um sistema computacional suportável por *hardware* regular, com tempo de processamento adequado, que produza saídas com uma margem de erro aceitável para a aplicação na indústria mineral.

## 1.2 Justificativas

Na maioria das minas de ouro e cobre, o controle diário do teor de minério e conseqüentemente a definição do destino do material lavrado, sejam as pilhas de estéril ou as plantas de beneficiamento, são baseados em análises químicas efetuadas em amostras coletadas nas frentes de lavra. O tempo de análise e emissão de resultados requeridos pelos laboratórios, ainda que localizados nas próprias minas, pode variar de muitas horas a alguns dias. Acrescentando-se o tempo necessário para coleta de amostras, tratamento e integração dos dados analíticos, é muito comum passarem-se alguns dias para liberar uma frente de lavra. Algumas minas solucionam esse problema estocando minério para garantir a continuidade da operação da planta de beneficiamento; outras, por baixa disponibilidade de frentes de lavra ou impedimentos para a formação de estoques, não raro tomam decisões precipitadas que acabam levando à diluição do minério ou ao ‘enriquecimento’ do estéril. No caso específico do depósito de Chapada, os testes metalúrgicos realizados não recomendam a formação de pilhas de estoque, pelo fato de que, uma vez exposto, o minério oxida-se rapidamente provocando redução na recuperação metalúrgica e conseqüentemente, perdas econômicas para o empreendimento. Neste sentido, a técnica de redes neurais pode constituir uma ferramenta útil na estimativa do teor de frente de lavra para definição de estéril e minério, antecipando a decisão que seria tomada posteriormente, até tardiamente, com as análises químicas.

As principais vantagens da utilização da técnica de redes neurais na solução de problemas geológicos são:

1. Não é necessário ter uma idéia precisa da influência real de certos parâmetros de entrada na obtenção das saídas desejadas, ou seja, pode-se não ter certeza da inclusão de determinado parâmetro como entrada da rede neural (Dyminski, 2000);

2. É possível a inclusão ou exclusão de parâmetros de entrada sem fazer alterações na arquitetura básica da rede;
3. *A não-linearidade*: uma rede neural constituída por conexões de neurônios não-lineares é ela mesma não-linear, e essa característica é distribuída por toda a rede. Essa propriedade é muito importante, particularmente se o fenômeno responsável pela geração do sinal (dado) de entrada for inerentemente não-linear;
4. Mapeamento de entrada-saída: o conhecimento é adquirido pela rede a partir de seu ambiente através de aprendizagem supervisionada, e armazenado nas forças de conexão entre os neurônios, isto é, nos pesos sinápticos. Isto é fundamentalmente diferente do processamento de informações clássico, onde procede-se formulando um modelo matemático das observações do ambiente, e depois validando o modelo com dados reais;
5. Adaptabilidade: as redes neurais têm capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente, isto é, uma rede treinada para operar em um ambiente específico, até *não-estacionário*, pode ser facilmente retreinada para lidar com as modificações nas condições operativas. A rede pode inclusive ser retreinada em outros ambientes distintos, no caso presente, em outros depósitos minerais;
6. Tolerância a falhas: é capaz de realizar computação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operação adversas, como exemplo se um neurônio ou suas conexões são danificadas a resposta global da rede não é seriamente prejudicada;
7. A técnica não requer a construção de modelos matemáticos complexos do problema a ser resolvido, e não necessita de estabelecimento de premissas sobre a distribuição estatística dos dados utilizados, tornando-a uma técnica de estimativa muito robusta.

## CAPÍTULO 2. MÉTODOS

---

A técnica de redes neurais artificiais é método a ser aplicado na resolução do problema que envolve o controle da mineralização do depósito de cobre-ouro de Chapada. Neste capítulo serão descritos os conceitos e os principais modelos matemáticos desenvolvidos na estruturação das redes. Serão focados os tipos de rede voltados a aplicações semelhantes a proposta neste trabalho. As aplicações da técnica envolvendo geologia, publicadas até o momento, são voltadas para a geotecnia ou estimativa de reservas, e serão aqui relatadas.

Inicialmente serão descritas as técnicas de análise estatística descritiva e geoestatística utilizadas na caracterização, correlação e distribuição espacial das variáveis envolvidas na aplicação proposta neste estudo. A descrição metodológica será resumida por se tratar de técnicas muito conhecidas e de uso generalizado.

### 2.1 Análise estatística descritiva

A primeira abordagem ao depararmos com uma quantidade significativa de dados é a estatística descritiva, que pode ser definida como um conjunto de técnicas destinadas a descrever e resumir os dados, objetivando tirar conclusões a respeito de características de interesse. Cada uma dessas características é denominada de *variável*.

As variáveis podem ser classificadas, no que tange aos valores que podem assumir, em dois grandes tipos: variáveis numéricas ou quantitativas e variáveis não numéricas ou qualitativas. A variável é qualitativa quando os possíveis valores que assume representam atributos e/ou qualidades. Quando as variáveis qualitativas indicam intensidades crescentes de realizações são classificadas como qualitativas ordinais; caso contrário, quando não é possível estabelecer uma ordem natural entre seus valores, elas são classificadas como qualitativas nominais. As variáveis quantitativas podem ser subdivididas em discretas e contínuas: discretas quando resultam de contagens, assumindo geralmente valores inteiros; contínuas quando assumem valores em números reais, geralmente provenientes de uma mensuração (Magalhães & Lima, 2002).

Podemos classificar as técnicas de estatística descritiva como univariadas, agrupando as medidas resumo de uma variável aleatória, e bivariadas, descrevendo as medidas de associação ou relacionamentos entre pares de variáveis aleatórias.

### 2.1.1 Estatística descritiva univariada

O conhecimento individual das variáveis de um conjunto de dados pode ser sumarizado por informações sobre a maneira pela qual estão distribuídos. Estas informações podem ser expressas em medidas de posição ou tendência central, medidas de dispersão e medidas de forma da distribuição dos dados.

A distribuição de dados de uma variável é inicialmente avaliada através de gráficos de frequência, construídos a partir tabelas de frequência, que consiste em listar os valores possíveis da variável, numéricos ou não, e fazer a contagem na tabela de dados brutos do número de suas ocorrências. O gráfico de barras utiliza o plano cartesiano com os valores da variável nos eixos das abcissas e as frequências ou porcentagens no eixo das ordenadas. O *histograma* consiste em retângulos contíguos com base nas faixas de valores da variável e com área igual à frequência relativa da respectiva faixa (Magalhães & Lima, 2002).

*Média, mediana e moda* são medidas de tendência central informando onde o centro da distribuição se posiciona. *Média* de um conjunto é a soma dos valores dividida pelo número total de observações; *mediana* é o valor que ocupa a posição central dos dados ordenados e; *moda* é o valor mais freqüente.

As medidas de dispersão indicam a variabilidade dos valores de uma variável, expressas pela *amplitude*, *variância* e *desvio padrão*. A *amplitude* é definida como a diferença entre o maior e o menor valor de um conjunto de dados. A *variância* é a média dos quadrados das diferenças entre os valores observados e a média. O *desvio padrão* é simplesmente a raiz quadrada da variância, sendo mais utilizado que esta por apresentar-se na mesma unidade da variável que está sendo medida. São medidas fortemente influenciadas por valores erráticos extremos.

A forma da distribuição de frequência pode ser primariamente medida *pelo coeficiente de assimetria* e *pelo coeficiente de variação*. O *coeficiente de assimetria* indica a simetria do histograma e apresenta os indícios preliminares sobre a normalidade da distribuição. É extremamente sensível aos valores extremos, e mais importante que a magnitude do coeficiente, é o sinal do mesmo (Isaaks e Srivastava, 1989). Em conjuntos de dados

geoquímicos com concentração de elementos menores, como é o caso dos teores de cobre e ouro do depósito de Chapada, o coeficiente de assimetria é tipicamente positivo. O coeficiente se aproxima do zero quando o histograma tende a simetria e a média se aproxima da mediana, comportamento típico da distribuição normal.

O *coeficiente de variação (CV)* é a razão entre o desvio padrão e a média, sendo utilizado como um índice de variabilidade do conjunto de dados. É bastante utilizado como referência sobre o grau de regularidade da distribuição de teores em depósitos minerais, sendo expresso em porcentagem ou em valor absoluto.

O gráfico de probabilidade normal é outra ferramenta para avaliar a normalidade da distribuição dos dados de uma variável, onde os valores observados são plotados em um gráfico de dispersão contra os valores esperados de uma distribuição normal. No eixo das ordenadas são lançados ordenadamente os valores padronizados de uma distribuição normal para os desvios da média (resíduos) de cada observação. Se os resíduos observados plotados no eixo das abcissas forem normalmente distribuídos, os pares do gráfico tenderão a se alinhar segundo uma reta. Alternativamente transformando o eixo das abcissas em escala logarítmica os pares deverão alinhar-se retilinearmente caso a variável siga a distribuição lognormal. É possível ainda neste gráfico detectar valores extremos que formarão pares isolados.

### **2.1.2 Estatística descritiva bivariada**

A comparação entre as distribuições e relacionamentos entre variáveis é um dos temas mais frequentes da estatística aplicada a geociências, e os aspectos mais interessantes e importantes de um conjunto de dados geológicos estão nas associações e dependências entre seus elementos. Serão descritas nesta seção as ferramentas de comparação de distribuição de pares de variáveis utilizadas neste estudo.

A forma mais comum de visualização de dados bivariados é o *gráfico de dispersão*, que consiste simplesmente em um gráfico bidimensional  $x$ - $y$  onde os valores de uma variável são plotados no eixo  $x$  e os da outra variável no eixo  $y$ . Quanto menor a dispersão dos pontos formados pelos pares de variáveis maior é a associação entre as distribuições destas variáveis. A identificação de valores erráticos é uma aplicação valiosa deste tipo de gráfico, que é muito utilizado desde a validação de dados iniciais até na interpretação de resultados finais (Isaaks e Srivastava, 1989).

O *coeficiente de correlação* mede a dependência linear entre duas variáveis aleatórias calculado da seguinte forma:

$$r = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - m_x)(y_i - m_y)}{\sigma_x \sigma_y} \quad (\text{coeficiente de Pearson})$$

onde  $n$  é o número de dados;  $x_1, \dots, x_n$  são os valores da primeira variável ( $X$ ) com respectivos desvio padrão ( $\sigma_x$ ) e média ( $m_x$ ); e  $y_1, \dots, y_n$ ,  $\sigma_y$  e  $m_y$  são os mesmos parâmetros para a segunda variável ( $Y$ ). O coeficiente de correlação ( $r$ ) entre dois conjuntos de dados é sempre um número entre  $-1$  e  $1$ , tendendo a  $1$  quando as variáveis são positivamente correlacionadas, e a  $-1$  quando negativamente correlacionadas. É importante ressaltar que a correlação igual a zero não indica independência, e sim que não existe dependência linear entre as variáveis. A força de uma associação pode ser avaliada através do *coeficiente de determinação* determinado por  $r^2 * 100$ , que expressa em porcentagem a fração da variância total de  $X$  e  $Y$  explicado pela relação linear.

A significância da correlação linear pode ser avaliada através da aplicação do teste de hipótese para o coeficiente de correlação igual a zero ( $r=0$ ), ou seja, a hipótese nula afirma que não há relação linear alguma entre as variáveis. O teste utiliza a distribuição  $t$  de Student calculada pela equação que se segue:

$$t = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}$$

onde  $t$  se distribui com  $\varphi=n-2$  graus de liberdade,  $n$  é o número de pares amostrais  $(x_i, y_i)$ ,  $i=1, 2, \dots, n$ , e  $r$  é o coeficiente de correlação calculado das variáveis  $X$  e  $Y$ . Em valores absolutos, se o coeficiente de correlação calculado for menor que o tabelado significa dizer que a hipótese nula ( $H_0: \rho=0$ ) não pode ser rejeitada, isto é, não existe correlação linear entre as variáveis.

## 2.2 Análise geoestatística

Serão descritos nesta seção somente os elementos da análise geoestatística aplicados no presente estudo, compilados a partir do texto “Geoestatística Aplicada” de Sturaro (2000).

A diferença básica entre a estatística clássica e a geoestatística, consiste em que, a primeira requer valores das amostras independentes espacialmente, enquanto que a segunda requer valores das amostras correlacionadas (dependentes) no espaço. Por esta característica, a geoestatística tem tido grandes aplicações em geologia, principalmente para efetuar estimativas e/ou simulações de variáveis em locais não avaliados.

Normalmente os trabalhos que requerem um entendimento do fenômeno natural, como, por exemplo, a estimativa em locais não amostrados, necessitam de modelos matemáticos que dividem-se basicamente em: determinísticos e probabilísticos.

Os modelos determinísticos são os que determinam o resultado de um processo de acordo com uma lei bem definida e, assim, só podem ser empregados nos processos onde todos os componentes estão bem caracterizados e a influência dos mesmos no processo é bem conhecida. Infelizmente, poucas são as aplicações em Ciências da Terra, onde todos os fatores de um fenômeno natural são conhecidos suficientemente, permitindo um enfoque determinístico.

Os modelos probabilísticos tratam os dados como resultados de um processo aleatório que não corresponde exatamente à realidade, visto que o fenômeno que gerou uma determinada condição geológica, como jazidas minerais, áreas poluídas e outros, são extremamente complicados e o entendimento a respeito deles é tão pobre que sua complexidade parece ter um comportamento aleatório. Isto, entretanto, não significa que os fenômenos são efetivamente aleatórios, mas sim que se ignora muito a respeito destes processos. Desta forma, os modelos probabilísticos surgem como um processo alternativo eficaz para compreender os resultados originados de um fenômeno natural. Este tipo de modelamento foi o empregado neste trabalho para a caracterização das variáveis de teores de cobre e ouro, através das técnicas geoestatísticas que serão apresentadas nos próximos tópicos.

Outro conceito fundamental para a geoestatística é a regionalização das variáveis. Uma variável pode ser considerada regionalizada, se a mesma apresentar uma distribuição no espaço, juntamente com um determinado grau de correlação espacial. A teoria das variáveis regionalizadas está fundamentada nos modelos probabilísticos, onde as variáveis são consideradas como a realização única de uma determinada função aleatória (MATHERON, 1962 *in* STURARO, 2000). Desta forma, é necessário conhecer as características do processo

aleatório em que a variável está compreendida, podendo ser obtidas a partir dos trabalhos de amostragem, bem como de algumas suposições de estacionaridade do processo aleatório. A hipótese de estacionaridade assume que seja constante o valor médio esperado, para diversos locais. Assim, para cada par de dados separados por uma distância  $h$  qualquer, é considerado como uma realização diferente das variáveis regionalizadas.

### 2.2.1 Análise variográfica

Uma das principais características das variáveis regionalizadas, constitui-se na variabilidade espacial ou continuidade, cujo entendimento e modelamento representa a base de toda a análise geoestatística. Em geoestatística esta análise é feita para avaliar a dependência de uma variável com ela mesma, mas separadas por um vetor  $h$ .

Se uma variável regionalizada  $x(i)$  for coletada em diversos pontos  $i$ , o valor de cada ponto estará relacionado com valores obtidos a partir de pontos situados a uma certa distância  $\Delta h$  e a influência será tanto maior quanto menor for à distância entre os pontos. O grau de relação entre pontos numa certa direção pode ser expresso pela covariância, sendo os pontos regularmente espaçados por múltiplos inteiros de  $\Delta h$ . Para uma distância  $\Delta h$  infinitamente pequena a covariância e a variância se tornam muito próximas, porém para  $\Delta h$  maiores, a covariância diminui enquanto a variância aumenta, ou seja, ocorre progressivamente maior independência entre os valores obtidos a distâncias cada vez maiores. Através deste procedimento, o grau de dependência entre uma variável para com ela mesma, separada por um vetor  $h$ , pode ser captado pelo coeficiente de correlação, covariância e ainda pelo momento de inércia, que pode ser representado por uma função denominada variograma.

A função variograma é derivada do momento de inércia, calculado para uma variável  $V(x)$  em diversos intervalos de distância de um vetor  $h$ . O momento de inércia, definido neste contexto como variograma, constitui-se na metade da média das diferenças quadráticas entre as coordenadas de cada par de pontos do diagrama de dispersão espacial de  $V(x)$ , ou seja:

$$\text{Variograma} = \frac{1}{2n} \sum_{i=1}^n \left( V(x) - V(x+h) \right)^2$$

O fator  $1/2$  da equação, representa a distância ( $\cos 45^\circ$ ) perpendicular dos pontos em relação à linha de 45 graus do diagrama de dispersão. Este aspecto, conduz muitos geoestatísticos a denominar de semi-variograma para o momento de inércia, contudo, por uma questão de simplicidade, é comum utilizar o termo variograma .

Desta forma, quando se calcula o momento de inércia para vários intervalos de distância, elabora-se a seguir um gráfico para uma determinada direção, denominado de variograma experimental da variável  $V(x)$ . Estes variogramas são normalmente feitos para várias direções, notadamente aquelas que possuem maior e menor continuidade da variável, constatado em trabalhos preliminares.

A figura 2.1 exibe a configuração gráfica básica da função variograma, cujos principais parâmetros são descritos a seguir:

**-Amplitude Variográfica (a):** A medida que a distância entre os pares aumenta, a variabilidade tenderá a aumentar até atingir um determinado nível. A distância onde o variograma atinge este nível é considerada a amplitude variográfica, também denominada de alcance ou “range”;

**-Patamar (C):** Representa o nível de variabilidade onde o variograma se estabiliza. Este patamar deve ser teoricamente igual à variância estimada a priori, ou seja a variância populacional. Este parâmetro é também denominado de "sill";

**-Efeito Pepita( $C_0$ ):** Para distância igual a zero ( $h=0$ ), o variograma deveria apresentar variabilidade nula. Entretanto vários fatores como erros de amostragens, erros de medidas ou ainda microregionalizações da variável em análise, causam uma descontinuidade na origem do variograma, denominada de efeito de pepita.

A relação entre os parâmetros  $C_0$  e  $C$ , indicada por  $E$ , é denominada de efeito de pepita relativo e expressa o grau de aleatoriedade do fenômeno regionalizado (Garcia, 1988 *in* Sturaro, 2000). A classificação desta componente aleatória é assim definida:

$E < 0,15$  : componente aleatória pequena

$0,15 < E < 0,30$  : componente aleatória significativa

$E > 0,30$  : componente aleatória muito significativa




Figura 2.1- Gráfico básico de uma função variograma.

Após a elaboração dos variogramas experimentais direcionais, a etapa seguinte consiste em estabelecer um modelo matemático, que represente da melhor forma possível a variabilidade em estudo. Os modelos variográficos podem ser subdivididos em dois grupos: o modelos com patamar e modelos sem patamar.

Nos modelos com patamar a função variograma aumenta a medida que incrementa a distância, até atingir um patamar ("sill"), onde a função se estabiliza. Este patamar, teoricamente, deve ser igual à variância da população. Os modelos sem patamar apresentam um aumento constante da variabilidade à medida em que a distância é incrementada, isto é, podem ser generalizados como modelos lineares. Os principais modelos estão representados na figura 2.2.




Figura 2.2 - Modelos variográficos.

O modelo esférico, muito usado no ajuste de variogramas de variáveis geológicas, é definido pela equação a seguir:

$$\gamma(h) = \begin{cases} C \times 1.5 \frac{h}{a} - 0.5 \left(\frac{h}{a}\right)^3 & \text{para } h \leq a \\ C & \text{para } h > a \end{cases}$$

onde **C** é o patamar e **a** representa a amplitude variográfica. Quando dos ajustes deste modelo, aplica-se usualmente a regra de que a tangente na origem, atinge o patamar a uma distância de 2/3 da amplitude (**a**).

### 2.2.2 Krigagem ordinária

Uma necessidade constante na área de Geociências, principalmente em cartografia, é a estimativa de valores em locais onde não foram feitas amostragens. Esta fase constitui-se num passo importante, visto que a malha de pontos estimada será responsável pela qualidade dos mapas a serem gerados.

Dentre os métodos de estimativas, comumente empregados, o método geoestatístico da krigagem ordinária pode ser considerado como o melhor estimador linear sem viés, dado às seguintes características:

*linearidade*: as estimativas são feitas através de uma combinação linear dos dados;

*sem viés*: o método objetiva que o erro residual médio seja igual a zero;

*melhor estimador*: o método objetiva minimizar a variância dos erros.

As duas últimas proposições acima são difíceis de serem concebidas do ponto de vista prático, visto que não se conhecem os valores reais dos pontos estimados para se avaliar o erro e a variância verdadeiros. Para superar estes aspectos, a krigagem ordinária baseia-se em um modelo probabilístico, cujo erro residual médio, bem como a variância dos erros podem ser estimados. Desta forma, podem-se atribuir pesos às amostras usadas nas estimativas, de tal modo que o erro médio seja zero e a variância dos erros seja mínima. O desenvolvimento teórico da krigagem inicia-se com a formulação matemática do erro de estimativa e da variância dos erros estimados, apresentadas a seguir (Isaaks & Srivastava, 1989, Kim, 1990, Journel & Huijbregts, 1978 e Journel, 1988 in Sturaro, 2000).

Supondo-se a estimativa de um ponto não amostrado, através de uma combinação linear dos pesos de amostras, situados em uma vizinhança definida ao redor deste ponto:

$$\hat{V} = \sum_{j=1}^n w_j v_j$$

O erro cometido nesta estimativa constituirá na diferença do valor estimado com o valor real no ponto:

$$\text{erro no ponto estimado} = r_i = \hat{V}_i - V_i$$

e o erro médio após uma série de estimativas  $k$ , é dado por:

$$m_r = \frac{1}{k} \sum_{i=1}^k r_i = \frac{1}{k} \sum_{i=1}^k (\hat{V}_i - V)$$

Como já expresso anteriormente, os valores reais não são conhecidos. Este problema é solucionado em geoestatística, através de um modelo probabilístico em que, os valores estimados são resultados de um processo aleatório estacionário. Neste modelo, assume-se que o valor médio esperado é constante para as diversas localizações, ou ainda, que todos os valores avaliados constituem-se em variáveis aleatórias de uma mesma população. Desta forma, cada par destas variáveis possuem uma distribuição conjunta que depende somente da separação entre dois pontos e não das suas localizações.

Todos os valores neste modelo são vistos como o resultado de uma variável aleatória, tanto as amostras como o valor desconhecido a ser estimado. O valor a ser estimado por sua vez, também é uma variável aleatória, visto que ele será uma combinação linear das variáveis aleatórias, que são as amostras, ou seja:

$$\hat{V}(x_0) = \sum_{i=1}^n w_i V(x_i)$$

Da mesma forma, o erro da estimativa, definido como a diferença entre o valor estimado pelo modelo aleatório e o valor verdadeiro, é também considerado uma variável aleatória, isto é:

$$R(x_0) = \hat{V}(x_0) - V(x_0)$$

Por substituição, o erro da estimativa, pode ser assim definido:

$$R(x_0) = \sum_{i=1}^n w_i V(x_i) - V(x_0)$$

A condição de não viés, que estabelece o erro residual médio igual a zero, pode então ser desdobrada analiticamente da seguinte forma:

$$\begin{aligned} E\{R(x_0)\} &= E\left\{\sum_{i=1}^n w_i V(x_i) - V(x_0)\right\} \\ &= \sum_{i=1}^n w_i E\{V(x_i)\} - E\{V(x_0)\} \end{aligned}$$

Pela hipótese da estacionaridade:

$$\begin{aligned} E\{R(x_0)\} &= \sum_{i=1}^n w_i E\{V\} - E\{V\} \\ E\{R(x_0)\} &= 0 = E\{V\} \sum_{i=1}^n w_i - E\{V\} \\ E\{V\} \sum_{i=1}^n w_i &= E\{V\} \\ \text{e } \sum_{i=1}^n w_i &= 1 \end{aligned}$$

A principal característica da krigagem, consiste em avaliar a variância do erro de estimativa e tentar minimizá-la.

O erro de estimativa, como já foi dito é assim definido :

$$R(x_0) = \sum_{i=1}^n w_i V(x_i) - V(x_0)$$

Tendo em vista que a variância de uma combinação linear ponderada, pode ser equacionada em termos de covariância, segundo a expressão:

$$Var\left\{\sum_{i=1}^n w_i V_i\right\} = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \cdot \text{cov}\{V_i V_j\}$$

- variância do erro da estimativa pode então ser desdobrada:

$$\begin{aligned} Var\{R(x_0)\} &= Cov\{\hat{V}(x_0)\hat{V}(x_0)\} - Cov\{\hat{V}(x_0)V(x_0)\} - Cov\{V(x_0)\hat{V}(x_0)\} + Cov\{V(x_0)V(x_0)\} \\ Var\{R(x_0)\} &= Cov\{\hat{V}(x_0)\hat{V}(x_0)\} - 2Cov\{\hat{V}(x_0)V(x_0)\} + Cov\{V(x_0)V(x_0)\} \end{aligned}$$

- sendo que, o primeiro termo é a covariância de  $\hat{V}(x_0)$  com ela mesma, que é igual à variância de uma combinação linear de variáveis aleatórias:

$$Var\{\hat{V}(x_0)\hat{V}(x_0)\} = Var\left\{\sum_{i=1}^n w_i V_i\right\} = \sum_{i=1}^n \sum_{j=1}^n w_i w_j C_{ij}$$

O segundo termo, pode ser desdobrado da seguinte forma:

$$\begin{aligned} 2Cov\{\hat{V}(x_0)\hat{V}(x_0)\} &= 2Cov\left\{\left(\sum_{i=1}^n w_i V_i\right)V_0\right\} \\ &= 2E\left\{\sum_{i=1}^n w_i V_i V_0\right\} - 2E\left\{\sum_{i=1}^n w_i V_i\right\}E\{V_0\} \\ &= 2\sum w_i E\{V_i V_0\} - 2\sum w_i E\{V_i\}E\{V_0\} \\ &= 2\sum_{i=1}^n w_i Cov\{V_i V_0\} \\ &= 2\sum_{i=1}^n w_i C_{i0} \end{aligned}$$

O terceiro termo é a covariância da variável aleatória  $V(x_i)$  com ela mesma, que é igual à variância de  $V(x_0)$ . Pela condição de estacionaridade, todas as variáveis aleatórias têm a mesma variância  $\sigma^2$ , assim:

$$Cov\{V(x_0)V(x_1)\} = \sigma^2$$

Finalmente, após estas deduções, a variância dos erros de estimativas pode ser expressa pela sua equação básica:

$$\sigma_k^2 = \sigma^2 + \sum_{i=1}^n \sum_{j=1}^n w_i w_j C_{ij} - 2\sum w_i C_{i,0}$$

A próxima etapa, conforme as propostas dos métodos geoestatísticos, é minimizar numericamente a equação da variância e igualar as  $n$  derivadas parciais de primeira ordem a zero. Isto resultará no clássico sistema de equações lineares simultâneas. Entretanto, existe a condição de não viés, que implica na somatória dos ponderadores do sistema ser igual a 1(um). Para contornar esta restrição, é empregada a técnica lagrangiana, que introduz um novo parâmetro na equação sem afetar sua igualdade. Assim, o sistema pode ser solucionado, resultando num conjunto de ponderadores cuja somatória é 1(### $w_i=1$ ).

Desta forma, o conjunto de ponderadores que minimiza a variância dos erros de estimativas, sob a condição de somarem 1, é obtido pela seguinte seqüência matemática:

$$\frac{\partial \sigma_R^2}{\partial w_i} = 0 \quad \text{para } i = 1, 2, 3, \dots, n$$

Desta derivada, resultam as seguintes equações, que representam a krigagem ordinária em termos de variograma:

$$\sum_{j=1}^n w_j C_{ij} - \mu = C_{i0} \quad \forall i = 1, \dots, n$$

$$\sum_{j=1}^n w_j = 1$$

que podem ser representadas matricialmente:

$$\begin{bmatrix} C_{11} & \cdot & \cdot & \cdot & C_{1n} & 1 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ C_{n1} & \cdot & \cdot & \cdot & C_{nn} & 1 \\ 1 & \cdot & \cdot & \cdot & 1 & 0 \end{bmatrix} \times \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \\ -\mu \end{bmatrix} = \begin{bmatrix} C_{10} \\ \cdot \\ \cdot \\ \cdot \\ C_{n0} \\ 1 \end{bmatrix}$$

[C]            [W]    [D]

Cuja solução é :

$$[W] = [C]^{-1} \times [D]$$

A variância dos erros, minimizada pela krigagem ordinária, é obtida através da solução da expressão:

$$\sigma_R^2 = \sigma^2 - [W][D]$$

Nota-se nas matrizes C e D a função de covariância para inúmeros pares de pontos. Esta função é originada do modelo variográfico efetuado para compreender a continuidade espacial da variável de interesse.

Em função do uso comum do variograma, tem-se para os modelos de funções aleatórias estacionárias, a seguinte relação entre variograma e a covariância:

$$C_{ij} = \sigma^2 - \gamma_{ij}$$

Nos processos de estimativa, esta relação possibilita trabalhar com a função variograma na fase de modelamento da variabilidade espacial e com a função covariância.

### 2.3 Redes neurais

As redes neurais artificiais, comumente chamadas “redes neurais” (RN’s) foram desenvolvidas a partir da idéia de funcionamento do cérebro humano, e da forma diferente como ele processa as informações, comparada ao computador digital convencional. Entende-se o cérebro como um “computador”, isto é, um sistema de processamento de informações, altamente complexo, não-linear e paralelo. Os constituintes estruturais do cérebro, conhecidos por neurônios, realizam certos procedimentos tais como reconhecimento de padrões, percepção

e controle motor muito mais rápido que os mais velozes computadores digitais existentes. Tipicamente os neurônios são de cinco a seis ordens de grandeza mais lentos que as portas lógicas em silício, enquanto os eventos são processados nos circuitos artificiais em nanossegundos ( $10^{-9}$  s) no cérebro eles acontecem em milissegundos ( $10^{-3}$  s). Entretanto, o cérebro compensa a taxa de operação relativamente lenta de um neurônio pelo número espantoso de neurônios com conexões maciças entre si. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões. O resultado é uma estrutura onde a eficiência energética é de aproximadamente  $10^{-16}$  joules por operação por segundo, enquanto que o valor correspondente para os melhores computadores atuais é de cerca de  $10^{-6}$  joules por operação por segundo (Haykin, 2001).

Pode-se definir uma rede neural artificial como um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Assemelha-se ao cérebro em dois aspectos:

- 1) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
- 2) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

A rede neural como um sistema de inteligência artificial deve ser capaz de, além de adquirir e armazenar conhecimento, aplicar o conhecimento armazenado para resolver problemas e adquirir novo conhecimento através da experiência.

Uma rede neural extrai seu poder computacional através de sua estrutura maciçamente paralelamente distribuída e de sua habilidade de aprender e portanto, de generalizar. A generalização se refere ao fato da rede neural produzir saídas adequadas para entradas que não estavam presentes durante a aprendizagem (treinamento).

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado.

Neurônio é a unidade de processamento fundamental para a operação de uma rede neural, que pode ser modelado esquematicamente como na figura 2.3. Três elementos básicos podem ser identificados no modelo neuronal:

- 1) Um conjunto de ligações chamadas sinapses ou elos de conexão, cada uma caracterizada por um peso  $w_{kj}$ , onde o índice  $k$  corresponde ao número do neurônio

em questão e  $j$  ao sinal de entrada. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos. Quanto maior o peso sináptico, maior será a contribuição da respectiva entrada para o *somador*;

- 2) Um *somador* para somar os sinais de entrada, ponderados pelos respectivos pesos sinápticos configurando um combinador linear, cujo resultado é o valor  $u_k$ ;
- 3) Uma *função de ativação* para restringir a amplitude da saída de um neurônio, também referida como função restritiva já que limita o intervalo permissível de saída a valores normalizados entre 0 e 1 ou  $-1$  e 1.

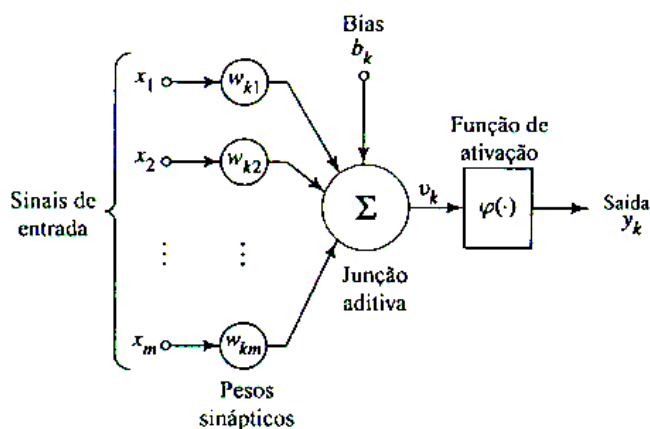


Figura 2.3: Modelo de um neurônio artificial. (Haykin, 2001).

O modelo neuronal mostrado na figura 2.3 inclui também um viés positivo ou negativo, aplicado externamente, representado por  $b_k$ , com o efeito de aumentar ou diminuir a entrada  $u_k$  da função de ativação.

Em termos matemáticos, um neurônio  $k$  pode ser descrito através das seguintes equações (Haykin, 2001):

$$u_k = \sum_{j=1}^m w_{kj} x_j$$

e

$$y_k = \varphi(u_k + b_k) \quad \text{ou} \quad y_k = \varphi(v_k)$$

onde  $x_1, x_2, \dots, x_m$  são os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;  $u_k$  é a saída do combinador linear devido aos sinais de entrada;  $b$  é o viés;  $\varphi(\cdot)$  é a função de ativação; e  $y_k$  é o sinal de saída do neurônio. O uso do viés  $b$  tem o efeito de aplicar

uma *transformação afim* à saída  $u_k$  do combinador linear, modificando o potencial de ativação  $v_k$ .

A função de ativação  $\varphi(v)$  que define a saída de um neurônio pode ser de três tipos básicos (figura 2.4):

a) Função de limiar ou “degrau”:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases}$$

b) Função linear:

$$\varphi(v) = \alpha v$$

onde  $\alpha$  é o coeficiente angular constante que limita os valores de  $\varphi(v)$  entre 0 e 1 ou  $-1$  e 1.


b) Função sigmóide: é a função mais utilizada na construção de redes neurais; pode assumir duas formas:

c.1) Função logística:

$$\varphi(v) = \frac{1}{1 + e^{-\alpha v}}$$

c.2) Função tangente hiperbólica:

$$\varphi(v) = \tanh(v) = \frac{e^{\alpha v} - e^{-\alpha v}}{e^{\alpha v} + e^{-\alpha v}}$$



Uma rede neural é constituída por diversos neurônios, que são conectados entre si e dispostos segundo a arquitetura da rede. As arquiteturas de rede são classificadas em três tipos fundamentalmente diferentes:

1) Redes alimentadas adiante com camada única:

Os neurônios estão organizados na forma de uma camada de entrada que se projeta sobre uma camada de saída de neurônios em sentido único, isto é, estritamente do tipo alimentada adiante (“feedforward”). A designação “camada única” se refere à camada de saída, pois na camada de entrada não é realizada qualquer computação. A figura 2.5 mostra o exemplo de uma rede com 4 nós (neurônios) tanto na camada de entrada como na de saída.




Figura 2.5: Rede alimentada adiante (“feedforward”) com uma única camada de neurônios (Haykin,2001).

## 2) Redes alimentadas diretamente com múltiplas camadas:

A segunda classe de redes neurais alimentadas adiante se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos com a função de intervir entre a entrada externa e a saída da rede. A adição de uma ou mais dessas camadas ocultas torna a rede capaz de extrair estatísticas de ordem elevada, habilidade esta particularmente valiosa quando o tamanho da camada de entrada é grande. É o tipo mais utilizado em aplicações de engenharia e geotecnia. A figura 2.6 ilustra uma rede com uma única camada oculta de tamanho 10-4-2, isto é, possui 10 neurônios de fonte, 4 neurônios ocultos e 2 neurônios de saída.




Figura 2.6: Rede alimentada adiante (“feedforward”) com múltiplas camadas: uma camada oculta e uma camada de saída (Haykin,2001).

### 3) Redes recorrentes:

Distingue-se de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, conforme a ilustração da figura 2.7. Este tipo de rede tem um comportamento dinâmico não-linear devido aos operadores de atraso unitário (“ $z^{-1}$ ”), sendo apropriadas para aplicações como equalizações adaptativas de canais de comunicação, processamento de voz, controle de instalações industriais e diagnósticos de motores automotivos.

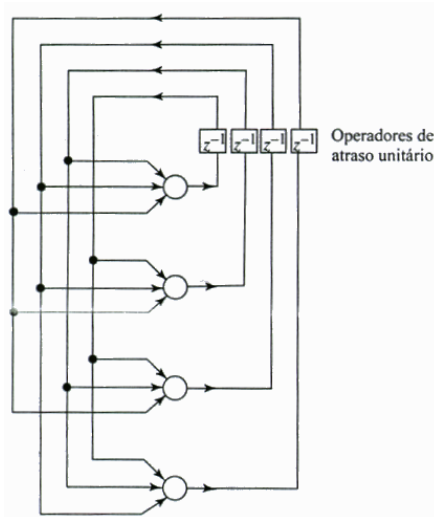


Figura 2.7: Rede recorrente sem neurônios ocultos (Haykin,2001).

O número de neurônios e de camadas está associado à complexidade do modelo pretendido, refletindo no número de parâmetros que serão estimados. Como orientação geral, o número de neurônios não pode ser muito pequeno se o problema a ser resolvido apresenta grande complexidade; e também não deve ser grande demais a ponto de prejudicar a capacidade de generalização da rede, caracterizando um ajuste excessivo (“overfitting”) (Diminski, 2000).

Lamentavelmente, não há uma teoria bem desenvolvida para otimizar a arquitetura de uma rede neural que deve interagir com um ambiente de interesse, ou para avaliar o modo como modificações na arquitetura da rede afetam a representação do conhecimento no interior da rede. Respostas satisfatórias para estas questões normalmente são encontradas através de

um estudo experimental exaustivo, com o projetista da rede neural sendo uma parte essencial do ciclo de aprendizagem estrutural (Haykin, 2001).

Para uma rede neural a tarefa de aquisição de conhecimento é iniciada a partir das observações (medidas) do ambiente no qual a rede deve operar. Normalmente, estas observações são inerentemente ruidosas, sendo sujeitas a erros devido a ruídos e imperfeições do sistema. De qualquer maneira, o conjunto de exemplos utilizados para treinar a rede neural é retirado dessas observações.

Os exemplos podem ser rotulados ou não-rotulados. Nos exemplos rotulados cada exemplo que representa um sinal de entrada é associado a uma resposta desejada correspondente, isto é, saída-alvo. Os exemplos não-rotulados consistem de ocorrências diferentes dos próprios sinais de entrada.

Um conjunto de dados de treinamento ou amostra de treinamento é um conjunto de registros de variáveis de entrada-saída, com cada registro consistindo de um ou mais sinais de entrada e as correspondentes respostas desejadas. Dado este conjunto de exemplos, o projeto de uma rede neural segue os seguintes passos:

- 1) Uma arquitetura apropriada é selecionada para a rede neural, com uma camada de nós de fonte (neurônios de entrada) em número geralmente igual aos parâmetros de entrada;
- 2) Um subconjunto de exemplos chamado conjunto de treinamento (“in sample”) é então utilizado para treinar a rede por meio de um algoritmo apropriado. Esta fase é chamada de aprendizagem ou treinamento;
- 3) O desempenho da rede treinada é testado com dados não apresentados anteriormente, estes dados são chamados conjunto de teste (“out of sample”). As saídas da rede neural alimentada com o conjunto de teste são então comparadas com os valores reais dos parâmetros de saída. Esta etapa é chamada generalização.

A diferença fundamental entre os projetos de uma rede neural e o processamento de informação clássico é que neste último, procede-se primeiramente formulando um modelo matemático das observações do ambiente, validando o modelo com dados reais, e então estruturando o projeto com base neste modelo. O projeto de uma rede neural, ao contrário, é baseado diretamente nos dados do mundo real, permitindo que o conjunto de dados fale por si mesmo. Assim, a rede neural não só fornece o modelo implícito do ambiente no qual ela está inserida, como também realiza a função de processamento de informação de interesse (Haykin, 2001).

## 2.4 Treinamento das redes neurais

Treinamento ou aprendizagem é o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (Mendel e McClaren in Haykin,2001). Esta definição do processo de aprendizagem implica na seguinte seqüência de eventos:

1. A rede neural é estimulada por um ambiente;
2. A rede neural sofre modificações nos seus parâmetros livres (pesos sinápticos) como resultado desta estimulação;
3. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

O conjunto preestabelecido de regras para a solução de um problema de treinamento é denominado algoritmo de aprendizagem. Existem vários algoritmos de aprendizagem que oferecem vantagens específicas para cada aplicação e diferem entre si pela forma como é feito o ajuste do peso sináptico de um neurônio. Os algoritmos mais comumente utilizados em aplicações de engenharia e geologia são o de retropropagação do erro (“error backpropagation”) e o de Levenberg-Marquardt (“LM”) ( Dyminski, 2000).

Existem cinco formas básicas de aprendizagem: 1) aprendizagem por correção do erro; 2) aprendizagem baseada em memória; 3) aprendizagem hebbiana; 4) aprendizagem competitiva; e 5) aprendizagem de Boltzmann. A aprendizagem por correção do erro fundamenta-se no princípio da filtragem ótima e é a regra adotada pela aplicação proposta no presente trabalho. A aprendizagem baseada em memória opera memorizando explicitamente os dados de treinamento. As aprendizagens hebbiana e competitiva são inspiradas em considerações neurobiológicas, e a aprendizagem de Boltzmann baseia-se em idéias da mecânica estatística.

A aprendizagem pode se dar segundo dois paradigmas: 1) aprendizagem supervisionada; e 2) aprendizagem não supervisionada.

A aprendizagem supervisionada, também chamada aprendizagem com um “professor”, é o modelo adotado na maioria das aplicações de geociências onde o “professor” é representado por um conjunto de exemplos de entrada-saída, constituindo um vetor de treinamento. Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro, sendo este definido como a diferença entre a resposta desejada e a resposta real da rede (figura 2.8). Este ajuste é feito passo a passo, iterativamente, com o objetivo de fazer a rede emular o professor e desta forma o conhecimento é transferido para a rede neural, que é a partir daí capaz de lidar com o ambiente por si mesma dispensando o “professor”. Esta forma de aprendizagem segue a regra da aprendizagem por correção de erro citada no parágrafo anterior. Como medida de desempenho para o sistema é usualmente utilizado o erro médio quadrático ou a soma de erros quadráticos sobre a amostra de treinamento.

No paradigma de aprendizagem não supervisionada, não há um “professor” externo e, portanto, não são fornecidos exemplos rotulados da função a ser aprendida pela rede. O mapeamento entrada-saída é realizado através da interação contínua com o ambiente, visando minimizar um índice escalar de desempenho.

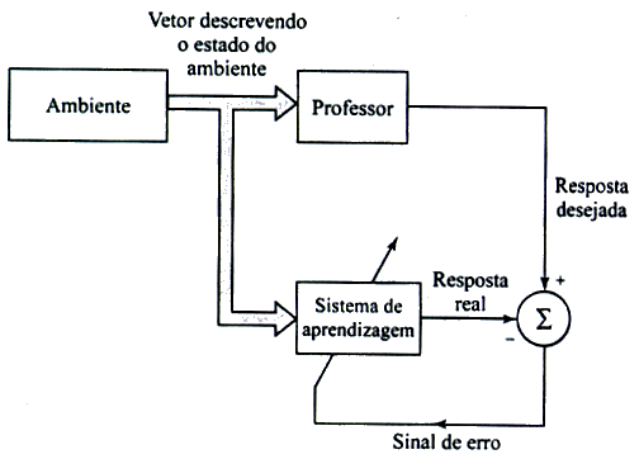


Figura 2.8: Diagrama esquemático da aprendizagem supervisionada. (Haykin, 2001)

#### 2.4.1 Algoritmo de Retropropagação do Erro em redes MLP

Nesta seção será descrita a aplicação do algoritmo de retropropagação do erro no treinamento de redes de múltiplas camadas, também chamadas de perceptrons de múltiplas camadas (MLP, *multilayer perceptron*), que é a classe de redes adotada neste estudo. Esse algoritmo é baseado na regra de aprendizagem por correção de erro e tem sido aplicado com sucesso na resolução de diversos problemas difíceis.

A aprendizagem por retropropagação do erro consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. Na propagação, um vetor de entrada é aplicado nos nós sensoriais (neurônios de entrada) da rede e seu efeito se propaga através das camadas até produzir um conjunto de saídas como a resposta real da rede. Nesta fase os pesos sinápticos da rede são todos fixos, enquanto que na fase seguinte, de retropropagação, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro que é então propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos sinápticos são ajustados para fazer com que a resposta real da rede se mova para mais perto da resposta desejada, em um sentido estatístico (Haykin, 2001). As equações de desenvolvimento do algoritmo de retropropagação mostradas a seguir foram extraídas de Haykin (2001).

O sinal de erro em um neurônio de saída  $j$  (figura 2.9), na iteração  $n$  (apresentação do  $n$ -ésimo exemplo de treinamento) é calculado pela equação:

$$e_j(n) = d_j(n) - y_j(n), \quad (\text{equação 2.1})$$

onde  $d_j(n)$  é o valor real de saída do neurônio  $j$  e  $y_j(n)$  sua estimativa na iteração  $n$ .




Figura 2.9: Diagrama de fluxo de sinal mostrando detalhes do neurônio de saída. (Haykin, 2001)

Se o valor instantâneo do erro quadrático para o neurônio  $j$  for definido como  $\frac{1}{2}e_j^2(n)$ , o somatório dos erros quadráticos instantâneos de todos os neurônios de saída podem ser escritos como:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (\text{equação 2.2})$$

onde o conjunto  $C$  inclui todos os neurônios da camada de saída da rede.

Considerando  $N$  o número total de exemplos contidos no conjunto de treinamento, o erro médio quadrático é obtido pelo somatório de todos os valores de  $\mathcal{E}(n)$ , dividido por  $N$ :

$$\mathcal{E}_{medio} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (\text{equação 2.3})$$

onde  $\mathcal{E}(n)$  e consequentemente  $\mathcal{E}_{med}$  é uma função de todos os parâmetros livres, isto é, pesos sinápticos e níveis de viés, da rede.

O objetivo deste algoritmo é ajustar os parâmetros de modo a minimizar  $\mathcal{E}_{med}$  que é a medida do desempenho do processo de treinamento da rede neural.

Considerando que o neurônio apresentado na figura 2.7 está sendo alimentado por um conjunto de saídas produzidos por uma camada de neurônios à esquerda, o fator de ativação  $v_j(n)$  produzido na entrada da função de ativação associada ao neurônio  $j$  é dado pela equação:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (\text{equação 2.4})$$

2.4)

onde  $m$  é o número total de entradas (excluindo o viés) aplicadas ao neurônio  $j$ . O peso sináptico  $w_{j0}$  (correspondente a entrada fixa  $y_0 = +1$ ) é igual ao viés  $b_j$  aplicado ao neurônio  $j$ . Assim, o sinal funcional de saída  $y_j(n)$  do neurônio  $j$  na iteração  $n$  é dado por:

$$y_j(n) = \varphi_j(v_j(n)) \quad (\text{equação 2.5})$$

O algoritmo de retropropagação aplica uma correção  $\Delta w_{ji}(n)$  ao peso sináptico  $w_{ji}(n)$ , que é proporcional à derivada parcial  $\partial \mathcal{E}(n) / \partial w_{ji}(n)$ . De acordo com a regra da cadeia do cálculo, este gradiente pode ser expresso como:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (\text{equação 2.6})$$

A razão  $\partial \mathcal{E}(n)/\partial w_{ji}(n)$  representa um fator de sensibilidade, determinando a direção de busca no espaço de pesos, para o peso sináptico  $w_{ji}(n)$ . Diferenciando ambos os lados da equação 2.2 em relação a  $e_j(n)$ , tem-se:

$$\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} = e_j(n) \quad (\text{equação 2.7})$$

Diferenciando ambos os lados da equação 2.1 em relação a  $y_j(n)$ , obtemos:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (\text{equação 2.8})$$

A seguir, diferenciando a equação 2.5 em relação a  $v_j(n)$ , tem-se:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)) \quad (\text{equação 2.9})$$

onde o uso do apóstrofe (no lado direito) significa a diferenciação em relação ao argumento.

Finalmente, diferenciando a equação 2.4 em relação a  $w_{ji}(n)$  obtem-se:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (\text{equação 2.10})$$

Aplicando as Eqs. 2.7 a 2.10 em 2.6 resulta:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = e_j(n) \varphi_j'(v_j(n)) y_i(n) \quad (\text{equação 2.11})$$

A correção  $\Delta w_{ji}(n)$  aplicada a  $w_{ji}(n)$  é definida pela regra delta:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (\text{equação 2.12})$$

onde  $\eta$  é uma constante que especifica a *taxa de aprendizagem* do algoritmo de retropropagação. O uso do sinal negativo na equação 2.12 indica o gradiente descendente no espaço dos pesos, ou seja, busca uma mudança de peso que reduza o somatório de erros quadráticos  $\mathcal{E}(n)$ . Por fim, aplicando-se a equação 2.11 em 2.12 chega-se a equação que define o ajuste a ser feito nos pesos sinápticos da rede:

$$\Delta w_{ji}(n) = -\eta e_j(n) \varphi_j'(v_j(n)) y_i(n) \quad (\text{equação 2.13})$$

onde  $\varphi_j'(v(n))$  é a derivada da função de ativação associada.

Ao definir a taxa de aprendizagem deve-se levar em conta que quanto menor for a constante  $\eta$ , menores serão as variações dos pesos sinápticos da rede de uma iteração para outra, permitindo a calibração mais precisa dos mesmos, embora o treinamento possa tornar-se extremamente lento. Por outro lado, uma constante  $\eta$  grande para acelerar a taxa de aprendizagem pode acarretar grandes modificações nos pesos sinápticos tornando a rede instável, e correndo o risco de ultrapassar a solução (valor mínimo da função de erro). Pode-se iniciar o treinamento com  $\eta$  relativamente alto (0,75) e, caso haja oscilações do valor de erro, diminuir  $\eta$  para 0,25 a 0,1 (Dyminski, 2000).

#### 2.4.2 Algoritmo de Levenberg-Marquardt (LM) em redes MLP

O algoritmo de Levenberg-Marquardt foi desenvolvido em 1963 e teve sua primeira aplicação no treinamento de redes neurais em 1994 (Hagan & Menhaj) com o objetivo de otimizar o algoritmo de retropropagação acelerando sua convergência.

O algoritmo LM pertence à classe de métodos “quase-Newton” desenvolvidos para aproximar-se da velocidade de convergência proporcionada pela utilização de derivadas de segunda ordem, muito maior que a obtida pela primeira derivada dos métodos de gradientes descendentes, mas sem ter que armazenar a matriz Hessiana, que contém as segundas derivadas. No caso de redes MLP onde a função de medida de desempenho é o somatório de erros quadráticos a matriz Hessiana  $H$  pode ser aproximada por:

$$H = J^T J$$

onde  $J$  é a matriz Jacobiana que contém as primeiras derivadas dos sinais de erros  $e(i)$  em relação aos pesos sinápticos e vieses. O gradiente  $g$ , que aponta as modificações necessárias nos pesos sinápticos, é estimado como:

$$g = J^T e$$

onde  $e$  é o vetor de erros da rede e  $J^T$  é a matriz Jacobiana transposta.

O método LM tem se mostrado o mais rápido no treinamento de redes neurais “feedforward” de tamanho moderado, isto é, algumas centenas de pesos sinápticos. Devido a limitações de memória computacional recomenda-se a utilização de outros algoritmos para redes maiores.

Na aplicação proposta neste trabalho foi testado no treinamento de redes neurais o algoritmo LM já programado no *software* MatLab (2000), módulo de Redes Neurais.

### 2.4.3 Validação Cruzada

A essência da aprendizagem por retropropagação é codificar um mapeamento de entrada-saída nos pesos sinápticos e limiares de um perceptron de múltiplas camadas (MLP). Espera-se que a rede se torne bem treinada de modo que aprenda o suficiente sobre o passado para generalizar no futuro. Desta perspectiva, o processo de aprendizagem se transforma em uma escolha de parametrização da rede para o conjunto de dados em questão, ou seja, testar e selecionar o modelo mais apropriado para resolver o problema.

O princípio da validação cruzada como ferramenta padrão da estatística pode ser aplicado como guia da aprendizagem. Primeiramente, o conjunto de dados disponível é dividido aleatoriamente em um conjunto de treinamento e em um conjunto de teste de generalização. O conjunto de treinamento é dividido adicionalmente em dois subconjuntos disjuntos: subconjunto de estimativa usado para selecionar o modelo, e subconjunto de validação usado para testar o modelo. O objetivo é validar o modelo com um conjunto de dados diferente daquele usado para estimar os parâmetros, de forma a avaliar o desempenho de vários modelos e assim, escolher o melhor.

Existe entretanto, um risco considerável de que o modelo assim selecionado, possa acabar ajustando excessivamente o subconjunto de validação (“overtraining”). Para minimizar esse risco, o desempenho de generalização do modelo é medido sobre o conjunto de teste, que é diferente do subconjunto de validação (Haykin, 2001).

Normalmente, uma rede MLP treinada com algoritmos de retropropagação aprende em estágios, aumentando a complexidade das funções conforme a sessão de treinamento avança. Em uma situação típica o erro médio quadrático decresce com o aumento do número de épocas (iterações) durante o treinamento: ele começa com um valor grande, decresce rapidamente e então continua diminuindo lentamente em direção a um mínimo local na superfície de erro. Se o objetivo é uma boa generalização, é muito difícil perceber quando é o melhor momento para encerrar o treinamento olhando apenas para a curva de aprendizagem. É possível que ocorra “overtraining” se a sessão de treinamento não for encerrada no ponto certo.

O início de “overtraining” pode ser detectado pela validação cruzada, utilizando os subconjuntos de estimativa e validação no método denominado *treinamento com parada antecipada* (“early stopping”). Neste método, o subconjunto de exemplos de estimativa é usado para treinar a rede na maneira usual, exceto por uma pequena modificação; a sessão de treinamento é interrompida periodicamente (após um determinado número de épocas), e a rede é testada com o subconjunto de validação. O processo periódico de estimativa seguida de validação realiza-se da seguinte forma:

1. Após um período de estimativa (treinamento), os pesos sinápticos e os níveis de viés da MLP são congelados, e a rede opera no seu modo direto para frente. O erro de validação é então medido para cada par entrada-saída do subconjunto de validação;
2. Quando a fase de validação é completada, a estimativa (treinamento) é reiniciada para novo período, e o processo é repetido.

O comportamento típico das curvas de aprendizagem dos subconjuntos de treinamento e validação é mostrado na figura 2.10. A curva do subconjunto de treinamento decresce monotonamente para um número crescente de épocas, da maneira usual. Já a curva do subconjunto de validação decresce para um mínimo e então começa a crescer conforme o treinamento continua. O ponto mínimo da curva de validação é indicado como o ponto ideal

para encerrar a sessão de treinamento. O que a rede aprende além deste ponto é essencialmente o ruído contido nos dados de treinamento.

Contudo, mesmo interrompendo o treinamento quando o valor de erro do subconjunto de validação for mínimo, ainda assim pode-se não ter certeza que os erros da rede estejam em patamares aceitáveis para o problema proposto. Neste caso o teste final de generalização da rede é realizado com o conjunto de teste de generalização, que é composto de dados não utilizados no treinamento mas oriundos da mesma população (Dyminski, 2000).




Figura 2.10: Treinamento com regra de parada antecipada baseada na validação cruzada. (Haykin, 2001)

A figura 2.11 ilustra exemplos de testes de generalização que podem ocorrer em uma rede hipotética com bom desempenho no caso (a) e generalização pobre (b).




Figura 2.11: (a) Dados ajustados adequadamente (boa generalização); (b) Dados ajustados em excesso (generalização pobre). (Haykin, 2001)

#### 2.4.4 Regularização bayesiana

Regularização é uma denominação genérica para métodos envolvendo a modificação da função de desempenho das redes neurais, que normalmente é a soma dos quadrados dos erros de treinamento, objetivando a melhoria de sua capacidade de generalização. O objetivo inicial do processo de treinamento é a minimização da soma dos erros quadrados:

$$E_D = \sum_{i=1}^n (t_i - a_i)^2 \quad (\text{equação 2.14})$$

onde  $t_i$  é a saída desejada e  $a_i$  representa a resposta da rede neural. O objetivo final do é uma rede que minimize os erros no conjunto de dados de treinamento, mas que será capaz de responder apropriadamente a novos dados (Foresee & Hagan, 1997) .

Na abordagem bayesiana proposta em 1992 por MacKay (*in* Foresee & Hagan, 1997) , a função de desempenho pode ser otimizada tratando os pesos sinápticos e vieses da rede como

variáveis aleatórias com distribuições específicas. Considerando a função objetivo  $F=E_D$  a regularização adiciona um termo tornando-se  $F= \beta E_D + \alpha E_w$ , onde  $E_w$  é a soma dos quadrados dos pesos sinápticos, e  $\alpha$  e  $\beta$  são parâmetros da função objetivo. O tamanho relativo destes parâmetros dita a ênfase do treinamento: se  $\alpha \ll \beta$  o algoritmo de treinamento minimizará os erros; se  $\alpha \gg \beta$  o treinamento priorizará a redução dos pesos sinápticos em detrimento dos erros produzindo assim uma suavização da resposta da rede. O principal desafio é estimar os valores corretos para  $\alpha$  e  $\beta$  de modo a obter uma aprendizagem eficiente, evitar o ajuste excessivo no treinamento (*overtraining*) e ainda garantir a capacidade de generalização da rede.

As equações mostradas a seguir foram compiladas de Foresee & Hagan (1997). Segundo os citados autores, no método de MacKay para treinamento das redes, a função densidade para os pesos sinápticos é atualizada conforme a regra de Bayes:

$$P(w | D, \alpha, \beta, M) = \frac{P(D | w, \beta, M)P(w | \alpha, M)}{P(D | \alpha, \beta, M)} \quad (\text{equação 2.15})$$

onde  $D$  representa o conjunto de dados,  $M$  é o modelo de rede neural utilizado, e  $w$  é o vetor de pesos sinápticos.  $P(w|\alpha,M)$  é a densidade a *priori*, que representa o nosso conhecimento dos pesos antes da coleta dos dados.  $P(D|w,\beta,M)$  é a função que define a probabilidade dos dados ocorrerem dados os pesos  $w$ .  $P(D|\alpha,\beta,M)$  é um fator de normalização para garantir que a probabilidade total seja igual a 1. Assumindo que o ruído no conjunto de dados de treinamento tem distribuição gaussiana, bem como a distribuição a priori dos pesos sinápticos, as probabilidades podem ser assim escritas:

$$P(D | W, \beta, M) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D), \quad (\text{equação 2.16})$$

$$P(D | w, \alpha, M) = \frac{1}{Z_D(\alpha)} \exp(-\alpha E_w)$$

onde  $Z_D(\beta) = (\pi/\beta)^{n/2}$  e  $Z_W(\alpha) = (\pi/\alpha)^{n/2}$ . Substituindo estas probabilidades na equação (2.15) Obtém-se:

$$P(w | D, \alpha, \beta, M) = \frac{\frac{1}{Z_W(\alpha)} \frac{1}{Z_D(\beta)} \exp(-(\beta E_D + \alpha E_W))}{\text{NormalizationFactor}} = \frac{1}{Z_F(\alpha, \beta)} \exp(-F(w)) \quad (\text{equação 2.17})$$

Na equação acima os pesos ótimos deveriam maximizar a probabilidade a *posteriori*  $P(w|D, \alpha, \beta, M)$ , que por sua vez significaria minimizar a função objetivo  $F = \beta E_D + \alpha E_W$ .

Se aplicarmos a mesma regra de Bayes para otimizar os parâmetros  $\alpha$  e  $\beta$  da função objetivo, temos que:

$$P(\alpha, \beta | D, M) = \frac{P(D | \alpha, \beta, M) P(\alpha, \beta | M)}{P(D | M)} \quad (\text{equação 2.18})$$

Assumindo uma densidade a *priori*  $P(\alpha, \beta | M)$  uniforme para  $\alpha$  e  $\beta$ , a maximização da probabilidade a posteriori pode ser atingida maximizando a função probabilidade  $P(D | \alpha, \beta, M)$  que equivale ao fator de normalização da equação 2.15. Desde que todas as probabilidades tenham distribuição gaussiana é possível resolver a equação 2.15 para o fator de normalização, como segue:

$$\begin{aligned} P(D | \alpha, \beta, M) &= \frac{P(D | w, \beta, M) P(w | \alpha, M)}{P(w | D, \alpha, \beta, M)} \\ &= \frac{\left[ \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \right] \left[ \frac{1}{Z_W(\alpha)} \exp(-\alpha E_W) \right]}{\frac{1}{Z_F(\alpha, \beta)} \exp(-F(w))} \\ &= \frac{Z_F(\alpha, \beta)}{Z_D(\beta) Z_W(\alpha)} \cdot \frac{\exp(-\beta E_D - \alpha E_W)}{\exp(-F(w))} = \frac{Z_F(\alpha, \beta)}{Z_D(\beta) Z_W(\alpha)} \end{aligned} \quad (\text{equação 2.19})$$

onde as constantes  $Z_D(\beta)$  e  $Z_W(\alpha)$  são conhecidas e  $Z_F(\alpha, \beta)$  pode ser estimado pelo polinômio de Taylor. Desde que a função objetivo tenha forma quadrática em torno do ponto mínimo,  $F(w)$  pode ser expandida em torno do ponto mínimo  $w^{MP}$ , onde o gradiente é igual a zero. Desta forma a constante  $Z_F$  pode ser resolvida como se segue:

$$Z_F = (2\pi)^{N/2} (\det(H^{MP})^{-1})^{1/2} \exp(-F(w^{MP})) \quad (\text{equação 2.20})$$

onde  $H = \beta \nabla^2 E_D + \alpha \nabla^2 E_W$  é a matriz Hessiana da função objetivo. Inserindo a equação 2.20 na equação 2.19 é possível encontrar os valores ótimos para  $\alpha$  e  $\beta$  no ponto mínimo segundo a equação abaixo:

$$\alpha^{MP} = \frac{\gamma}{2E_W(w^{MP})} \quad \text{e} \quad \beta^{MP} = \frac{n - \gamma}{2E_D(w^{MP})} \quad (\text{equação 2.21})$$

onde  $\gamma = N - 2\alpha^{MP} \text{tr}(H^{MP})^{-1}$  é o número efetivo de parâmetros usados na redução da função de erro e  $N$  é o número total de parâmetros da rede neural.

A otimização bayesiana dos parâmetros de regularização requer a computação da matriz Hessiana de  $F(w)$  no ponto mínimo  $w^{MP}$  e para tanto, Foresee e Hagan, 1997, propuseram a aproximação Gauss-Newton já utilizada no algoritmo de treinamento Levenberg-Marquardt. A computação adicional necessária para a regularização bayesiana é mínima e processa os seguintes passos:

- 1) Inicia os parâmetros  $\alpha$ ,  $\beta$  como “0” e “1” respectivamente, e os pesos sinápticos.
- 2) Processa um passo do algoritmo Levenberg-Marquardt para minimizar a função objetivo  $F(w) = \beta E_D + \alpha E_W$ ;
- 3) Calcula o número efetivo de parâmetros  $\gamma = N - 2\alpha \text{tr}(H)^{-1}$  fazendo uso da aproximação Gauss-Newton para a matriz Hessiana disponível no algoritmo Levenberg-Marquardt:  $H = \beta \nabla^2 F(w) \approx 2\beta J^T J + 2\alpha I_N$ , onde  $J$  é a matriz Jacobiana do conjunto de erros de treinamento;
- 4) Calcula novas estimativas para os parâmetros da função objetivo  $\alpha = \gamma / 2E_W(w)$  e  $\beta = n - \gamma / 2E_D(w)$ ;
- 5) Repete os passos “2” a “3” até a convergência do algoritmo.

O algoritmo Levenberg-Marquardt com regularização bayesiana funciona melhor quando as entradas e saídas da rede neural são normalizadas na escala entre -1 e 1. É importante deixar o algoritmo processar até que o número efetivo de parâmetros tenha convergido, que se expressa também na estabilização do somatório dos quadrados dos erros e dos quadrados dos pesos após seguidas iterações.

Na aplicação proposta neste trabalho foi testado no treinamento de redes neurais o algoritmo de regularização bayesiana com aproximação Gauss-Newton (GNBR) programado no *software* MatLab, módulo de RN.

## 2.5 Aplicações de Redes Neurais em Geologia

A utilização da técnica de redes neurais artificiais na modelagem de fenômenos geológicos teve início na última década e tem se intensificado principalmente no campo da geotecnia e geologia de engenharia. As aplicações em geologia econômica são mais escassas e dirigidas a exploração de petróleo e estimativa de reservas minerais.

Toll, 1996, fez uma revisão das aplicações de sistemas de inteligência artificial (AI) em geotecnia na primeira metade da década de 90, relacionando dezenas de artigos publicados em modelagem de terrenos, classificação de solos e rochas, desmonte de rocha, estabilidade de taludes, barragens, e outras aplicações mais voltadas para a engenharia. Dentre esses uma fração utiliza especificamente técnicas de redes neurais, de onde o citado autor destaca os trabalhos de Zhou & Wu (1994) no mapeamento de subsolo e de Basheer *et al* (1996) no mapeamento de permeabilidade de aterros. Ainda segundo Toll (1996), a utilização de redes neurais na classificação de maciço rochoso para estudos de estabilidade de taludes foi descrita por Millar & Hudson (1994), e também por Cai (1995) para planejamento de desmonte de rocha. Yi & Lindqvist (1995) aplicaram redes neurais na predição de parâmetros de qualidade de rocha (RQD).

Ainda no campo da geotecnia Dyminski (2000) testou no Brasil a técnica de redes neurais MLP com algoritmo de Levenberg-Marquardt na solução de problemas diversos da engenharia civil tais como: simulação de resultados de provas de carga dinâmica, análise do comportamento mecânico de solos arenosos de Ipanema e residual gnáissico do Rio de Janeiro, e simulação das características do subsolo do sítio da Usina Nuclear Angra 2. Esta última aplicação envolve muitos aspectos como disposição das camadas de solo, nível de água subterrâneo, resistência à penetração do solo (SPT) e modelagem topográfica. Em todos os casos os resultados obtidos foram bastante satisfatórios e tanto ou mais eficientes que as técnicas numéricas tradicionais.

O uso de redes neurais na determinação de litologias em poços de exploração de petróleo foi descrito por Rogers *et al* (1992), onde uma rede MLP com duas camadas alimentada com as variáveis raios gama, nêutrons e densidade, aprendeu a reconhecer tipos litológicos. Aplicações semelhantes têm sido relatadas sempre utilizando algoritmos de retropropagação, e mais recentemente Kumar *et al* (2000) interpolaram litologias a partir de informações de sondagem fundindo as técnicas de redes neurais MLP com lógica *fuzzy*, obtendo um resultado mais acurado que os métodos de RN conhecidos até o momento.

No campo da geologia econômica a utilização de redes neurais como método de estimativa de reservas minerais tem sido proposta e aperfeiçoada nos últimos sete anos por pesquisadores do grupo “AIMS Research” da Universidade de Nottingham, Inglaterra. Anteriormente ao grupo, Wu e Zhou (1993) propuseram o uso de redes MLP na modelagem da variação espacial e distribuição de teores de minério a partir de furos de sondagem em uma mina de cobre, lançando um simulador adaptativo chamado “DQP-Dynamic Quick Propagation” para determinar os parâmetros ideais de arquitetura e treinamento de redes neurais.

As primeiras publicações do grupo de Nottingham datam de 1995 quando Burnett, em sua tese de doutorado, e Denby e Burnett (1995), no simpósio APCOM XXV, lançam um sistema denominado “GEMNet” para estimativa de teor e reserva usando redes neurais no mapeamento de amostras em três dimensões. O sistema baseia-se no mapeamento da função não-linear locação-teor através de *redes de função de base radial* (RBF) indicadas para a solução de problemas de interpolação multivariada real. Uma RBF em sua forma básica (figura 2.12) apresenta três camadas: a camada de entrada constituída por nós de fonte (neurônios de entrada), uma única camada oculta de alta dimensionalidade que aplica uma função não-linear nos sinais de entrada, e uma camada de saída com função linear. Nesses trabalhos, os autores comparam os resultados de estimativa de reservas em minas de cobre e ferro usando redes neurais com técnicas clássicas e geoestatísticas, atingindo desempenho comparável a estas últimas (krigagem).

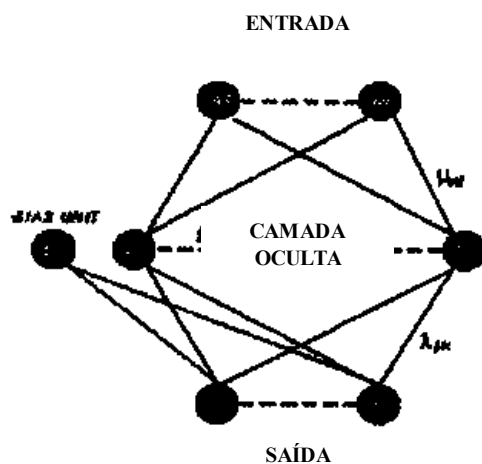


Figura 2.12: Modelo de uma Rede de Função de Base Radial (RBF).  
(modificada de Denby & Burnett, 1995)

Aperfeiçoamentos no sistema GEMNet foram introduzidas por Kapageridis e Denby (1997, 1998) com destaque para a introdução de mais uma variável de entrada: distância e teor das amostras vizinhas circundantes ao ponto a ser estimado. Nesse momento, a função de interpolação da rede neural tornou-se mais complexa e mais próxima à abordagem dos métodos geoestatísticos, melhorando significativamente a função de aproximação da estimativa.

Os desenvolvimentos mais recentes no sistema foram publicados por Kapageridis et al (1999a, 1999b) com a denominação “GEMNet II” onde buscou-se uma integração com pacotes comerciais de modelagem geológica tridimensional (software Vulcan). O sistema no estágio atual de desenvolvimento consiste de 3 módulos que atuam como segue:

- 1) Divide o espaço tridimensional cúbico em torno de cada amostra em 6 setores equidimensionais onde são treinadas 6 redes neurais RBF tendo como sinais de entrada: comprimento e teores das amostras vizinhas contidas no espaço e respectivas distâncias em relação à amostra de treinamento; e como saída desejada o teor da amostra de treinamento;
- 2) Treina uma única rede RBF tendo como entrada as variáveis coordenadas espaciais  $(X, Y, Z)$  das amostras e como saída os respectivos teores;
- 3) Integração final dos dados através do treinamento de uma rede RBF tendo como entrada as saídas dos dois módulos anteriores e como saída o teor da amostra de treinamento.

A despeito da evolução das aplicações de redes neurais em geologia nos últimos anos, a técnica ainda é pouco conhecida e utilizada na indústria mineral, empresas de engenharia geotécnica e construção civil. Ao contrário, as aplicações em áreas como mercado financeiro, telecomunicações, indústria automotiva, aeroespacial, eletrônica, e robótica são extensivas e bastante desenvolvidas.

## **CAPÍTULO 3. CARACTERIZAÇÃO DA ÁREA EM ESTUDO**

---

O depósito de cobre-ouro de Chapada é objeto de um projeto de mineração em desenvolvimento localizado no estado de Goiás, Brasil, cerca de 300 km a noroeste da cidade de Brasília. Atualmente, os recursos lavráveis do depósito são estimados em 215,9 milhões de toneladas a 0,365 % de cobre e 0,289 g/t de ouro, totalizando 788.000 t de cobre e 62,3 t de ouro contidas. Estes recursos estão planejados para serem minerados a céu-aberto, e tratados a uma vazão de 42.000 toneladas de minério por dia, gerando uma produção anual média de 43.102 t de cobre e 2,35 t de ouro durante 16 anos. O início de implantação do projeto está previsto para 2005.

### **3.1 Localização**


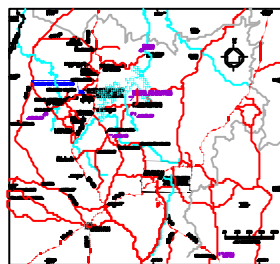
O depósito de Chapada localiza-se no município de Alto Horizonte, povoado antigamente denominado de Chapada Grande, distrito pertencente então, ao município de Mara Rosa, estado de Goiás, centro oeste do Brasil. Posiciona-se 320 km ao norte de Goiânia e 300 km a noroeste da cidade de Brasília ( figura 3.1 ).

O projeto abrange uma área de 3.000 ha pertencente à Mineração Maracá Indústria e Comércio S.A., subsidiária da Mineração Santa Elina Indústria e Comércio S.A.

### **3.2 Clima**

O clima nesta região pode ser dividido em estação chuvosa e estação seca. A estação chuvosa estende-se de outubro a abril, atingindo até 400 mm em meses de maior incidência de chuvas, enquanto que, na estação seca, nos meses de julho e agosto, a precipitação é praticamente inexistente. Juntamente com maio, constituem o período mais frio com temperaturas médias de 20°C a 22 °C. A temperatura média do período chuvoso (verão) situa-se entre 24°C e 26 °C.

**DEPÓSITO DE CHAPADA - COMÁS - BRASIL.**



**FIGURA 2.1 - Mapa de localização e contexto geológico regional.**

Em Chapada foi instalada uma estação meteorológica em 1980, que se manteve ativa até 1988. Durante este período, o ano de maior precipitação foi o de 1984 com um total de 1.797,4 mm e o ano de 1986, o de menor índice pluviométrico, 1.238 mm. O ano de 1985 marcou maior incidência de dias chuvosos, 117 dias, e o ano de 1987 o de menor incidência, 94 dias.

A mais alta taxa de evaporação ocorreu em 1981, totalizando 1.981 mm, dos quais 874 mm deu-se entre os meses de outubro a março e 1.107 mm, de abril a setembro.

### 3.3 Relevo

A área do projeto está localizada em um pediplano com altitude em torno de 400 m a 500 m acima do nível do mar, sobre o qual encontra-se comumente um horizonte de canga ferruginosa (figura 3.2).

O relevo local apresenta-se suavemente ondulado, onde predominam variações altimétricas em torno de 350 a 400 m. Destacam-se dois pontos cotados pela Diretoria de Serviço Geográfico (DSG), com 469 e 478 m, respectivamente, a sudeste da área do projeto correspondentes a morrotes sustentados por quartzitos.

Essa morfologia, segundo Almeida (1971) *in* Ribeiro Filho et al (1978), foi estabelecida no Quaternário, quando não houve mais fenômenos tecto-orogênicos de maior importância. Segundo os mesmos autores, o pediplano laterítico desenvolveu-se na parte centro-oeste do estado de Goiás sobre os metassedimentos do Grupo Araxá, bem como sobre as rochas pré-Araxá (área do projeto).

### 3.4 Hidrografia

A área do projeto apresenta baixa densidade de drenagens, as quais correm em direção ao rio Araguaia, fazendo parte, portanto, da bacia Amazônica.

O maior curso d'água local é o rio dos Bois, afluente do rio Crixás, correndo na direção leste-oeste na parte sul do projeto (figura 3.3). Possui um grande volume de água na época chuvosa, alcançando até 7 m acima do seu nível normal. No período da seca transforma-se praticamente num pequena drenagem, quando a lâmina d'água atinge no máximo 50 cm.

Na parte norte da área destaca-se o córrego Caraíba, local da futura barragem de rejeitos, e a oeste, o rio Formiga, ambos com regime perene e afluentes do rio dos Bois.



Figura 3.2 – Vista aérea da área do depósito de Chapada.

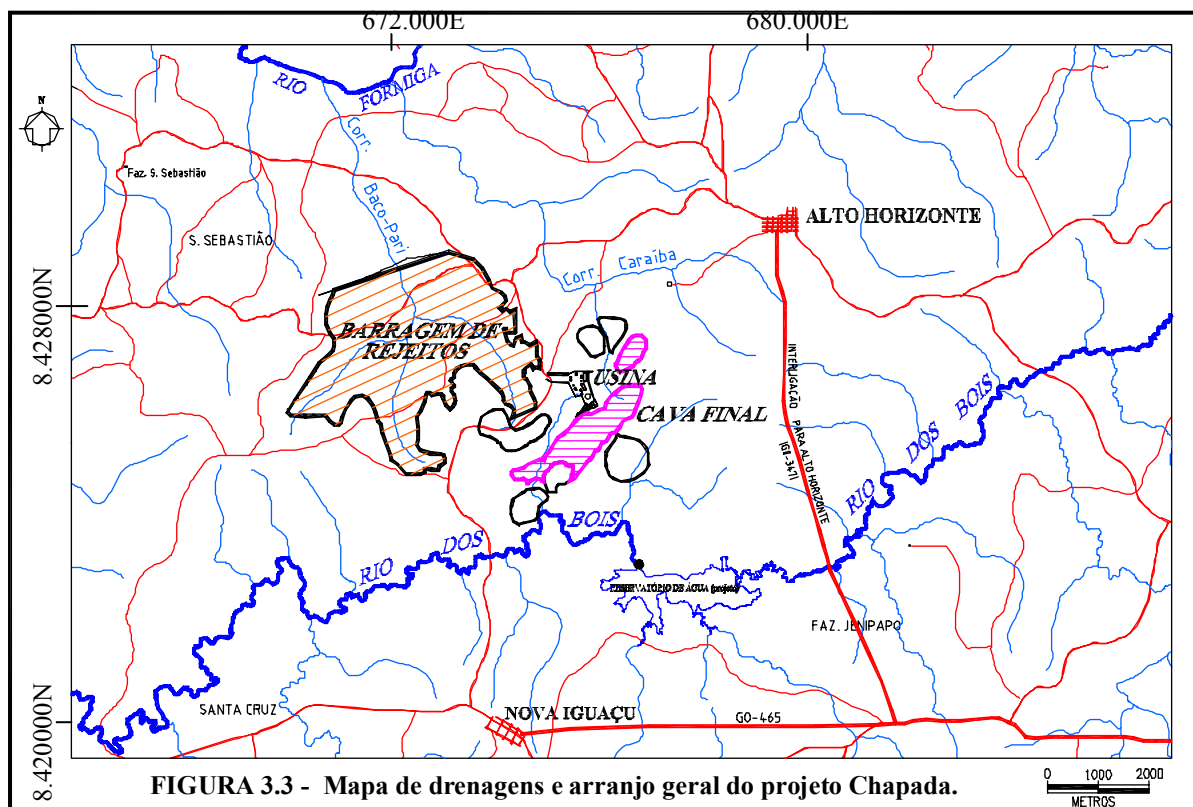


FIGURA 3.3 - Mapa de drenagens e arranjo geral do projeto Chapada.

Considerando a disponibilidade de água nas drenagens bastante irregular e sazonal, o projeto prevê o aproveitamento da água drenada na cava de lavra e a recirculação da água da bacia de rejeitos.

### **3.5 Vegetação e solos**

A vegetação predominante na região é tipicamente de cerrado, constituída por dois estratos arbóreos: o superior, de médio porte, formado por árvores e arbustos que atingem até 10 m de altura; e o inferior, onde predominam as gramíneas, as quais alcançam até 2 m de altura. O estrato superior caracteriza-se por espécimes com irregularidades nos caules e galhos, folhas grandes e ásperas, raramente com espinhos, em geral espaçadas entre si. O estrato inferior resente-se profundamente no período de estiagem, quando assumem um estado de latência ou morte aparente, favorecendo sobremaneira a propagação de queimadas. Nas cotas baixas e ao longo das drenagens ocorrem as matas ciliares, condicionadas, portanto ao nível freático.

Na área do projeto, mais especificamente na área da futura cava de lavra e usina de beneficiamento de minério, ocorreu um interessante processo de revegetação natural fruto da preservação exercida pela empresas atuantes na propriedade ao longo dos últimos 30 anos.

Os tipos de solos da região são predominantemente lateríticos e, secundariamente, solos areno-argilosos e aluviais. Os solos lateríticos, predominantes na área do projeto, exibem cores avermelhada a amarelada, são ricos em óxidos de ferro (limonita, principalmente) em função do processo de laterização. Os solos areno-argilosos ocorrem nas partes mais baixas e são solos transportados que apresentam bom desempenho no cultivo em função da riqueza em nutrientes proporcionada pela seleção natural do transporte. Os solos aluviais, que na área se resumem às margens do rio dos Bois, são argilo-arenosos, pouco espessos, com formação de estratos com coloração variada.

## 3.6 Geologia Regional

### 3.6.1 Contexto Geotectônico

A área estudada insere-se no contexto geotectônico da Província Estrutural do Tocantins definida por Almeida et al. (1977), balizada a leste pelo Cráton do São Francisco e a oeste pelo Cinturão Paraguai-Araguaia. Esta Província, segundo Marini et al. (1981), é compartimentada em três unidades principais: Maciço de Goiás, Faixa Uruaçu e Faixa Brasília. Fuck (1994) e Fuck et al. (1994) apresentaram uma nova compartimentação tectônica da porção oriental da Província Tocantins, subdividindo-a em cinco unidades principais (figura 3.4):

- (a) Zona Cratônica;
- (b) Faixa Brasília - Zona Externa, em contato com o Cráton do São Francisco;
- (c) Faixa Brasília - Zona Interna, a oeste da Zona Externa;
- (d) Maciço de Goiás, definido, originalmente, por Barbosa et al. (1969), a oeste da Zona Interna da Faixa Brasília e a leste das Faixas Paraguai e Araguaia;
- (e) Arco Magmático do oeste de Goiás.

Na Zona Cratônica (a), Fuck (1994) e Fuck et al. (1994) descreveram pequenos restos de embasamento e algumas coberturas aos grupos Paranoá e Bambuí. O primeiro é composto essencialmente por sedimentos terrígenos e carbonatos típicos de margem passiva, enquanto o segundo é constituído por depósitos glaciais (Formação Jequitai), seqüências argilocarbonatadas (Subgrupo Paraopeba) e um pacote de siltitos, arcóseos e grauvacas (Formação Três Marias).

De acordo com Fuck (1994), a Zona Externa da Faixa Brasília (b) é composta por rochas de idade neoproterozóica e paleo-mesoproterozóica. As rochas neoproterozóicas estão representadas pelos Grupos Paranoá e Canastra, e pelas formações Vazante, Ibiá, Paracatu e Minaçu. O paleo-mesoproterozóico está caracterizado pelos terrenos granito-gnáissicos, associações vulcano-sedimentares, granitos estaníferos, grupos Araí e Serra da Mesa, e pela Formação Ticunzal. Segundo estes autores, o limite oeste da Zona Externa é dado pelo front de nappes e empurrões do Grupo Araxá, com vergência para o Cráton do São Francisco.

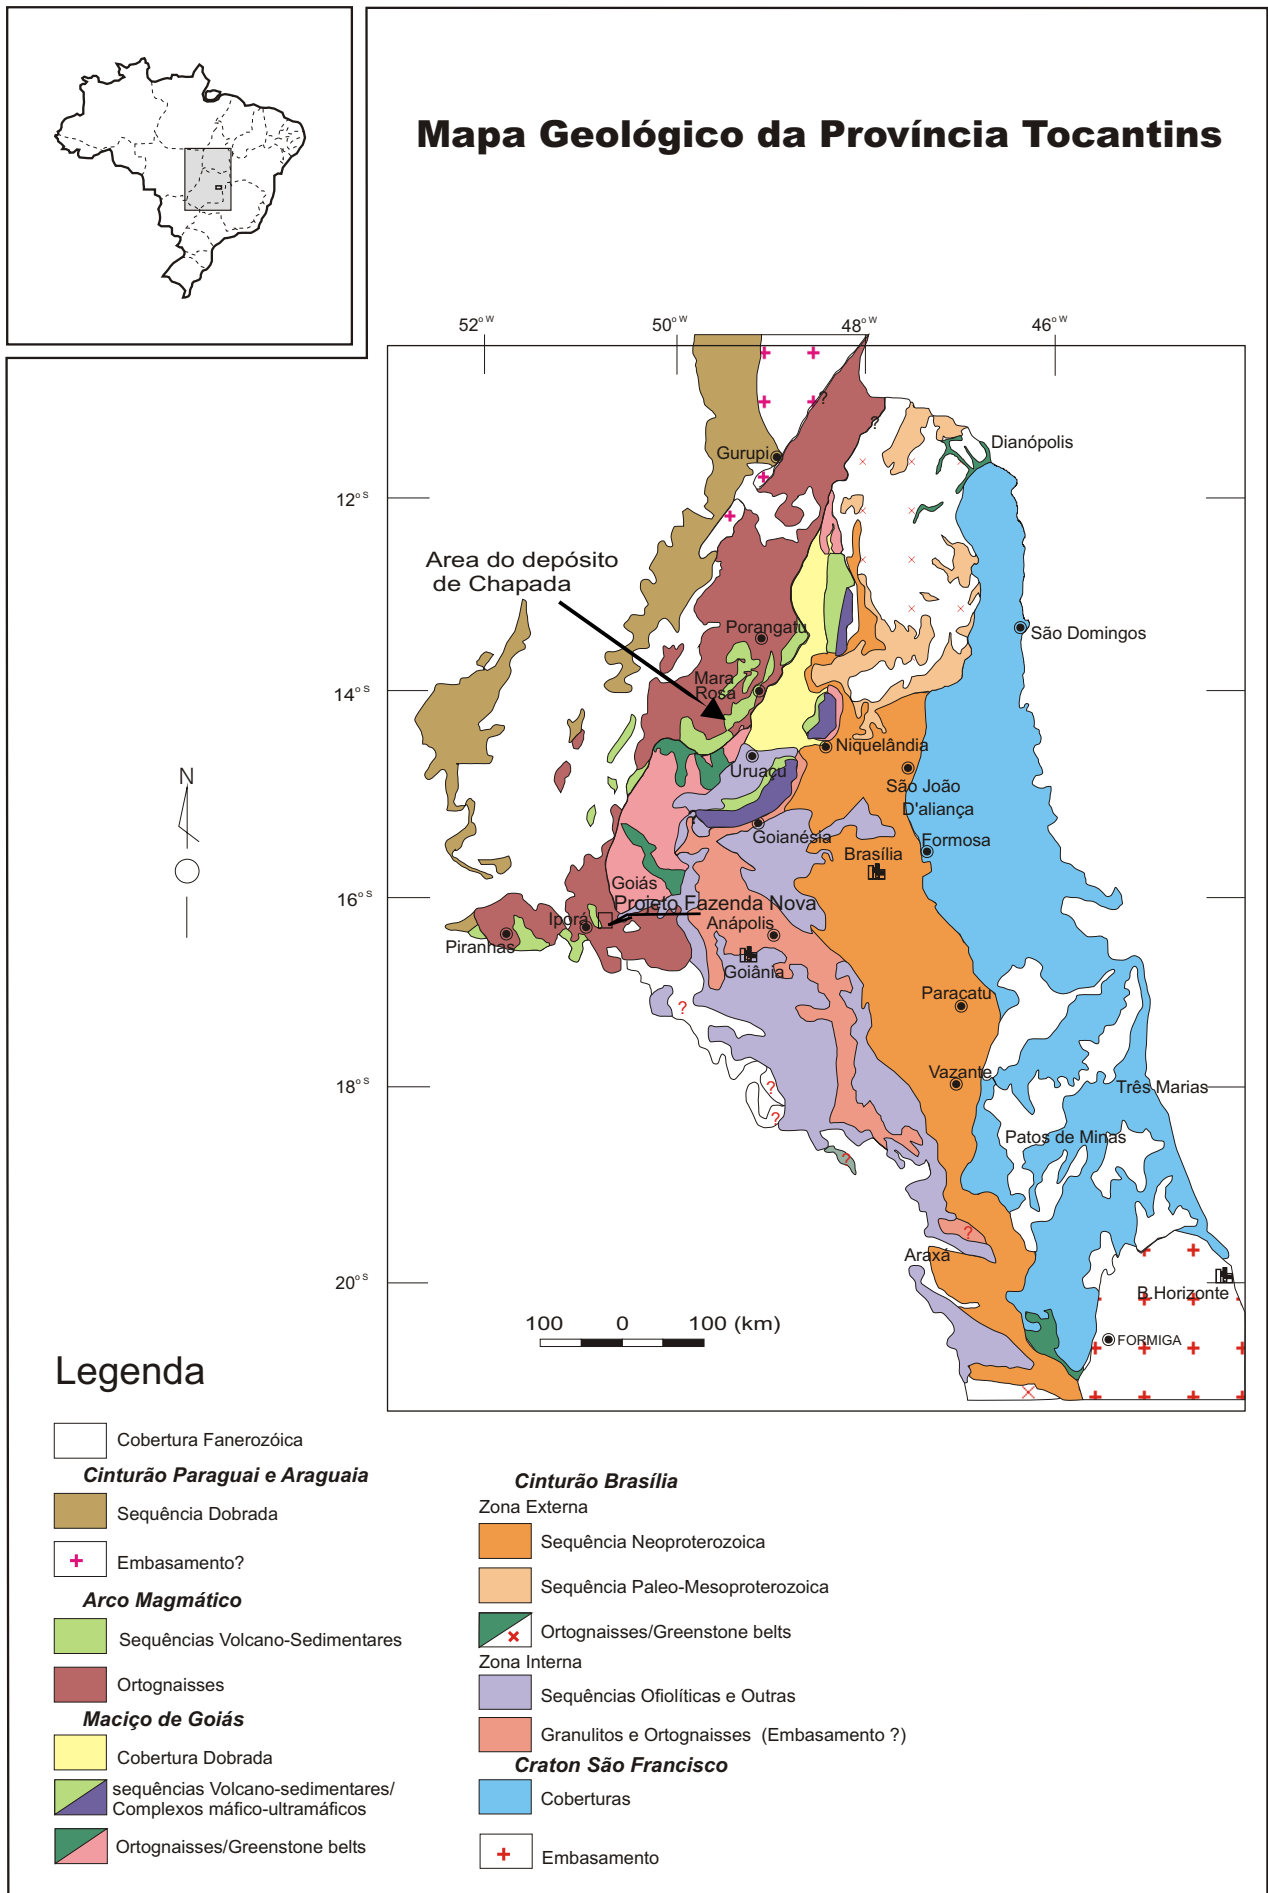


Figura 3.4- Mapa geológico da província Tocantins (modificado de Fuck et al. 1994 in Arantes et al., 1996)

Na Zona Interna da Faixa Brasília (c), os autores supracitados reafirmaram a ocorrência da Melange Ofiolítica (Drake Jr. 1980, Strider 1989, Strider & Nilson 1992 e Nilson 1993), inserida no Grupo Araxá, de idade neoproterozóica. Também estão inseridos nesta porção da província Tocantins as rochas de alto grau do Complexo Anápolis-Itauçu e rochas associadas (ortognaisses-migmáticos, seqüências vulcano-sedimentares e granitóides), considerados como *inlier*.

O Maciço de Goiás (d) é composto por rochas arqueanas e paleoproterozóicas (Marini et al. 1981). Dentre as rochas arqueanas encontram-se terrenos granito-gnáissicos, *greenstone belts* e cinturões granulíticos. As rochas do paleoproterozóico estão representadas por complexos gabro-anortosíticos acamadados, seqüências vulcano-sedimentares e intrusões graníticas. Nesta unidade estão inseridos os terrenos arqueanos granito-*greenstone* de Goiás, Crixás, Guarinos e Pilar de Goiás, e os terrenos paleo-mesoproterozóicos representados pelos complexos máfico-ultramáficos de Barro Alto Niquelândia e Canabrava e as seqüências vulcano-sedimentares associadas de Jucelândia, Coitezeiro e Palmeirópolis.

A última unidade tectônica discriminada por Fuck (1994) e Fuck et al. (1994) é o Arco Magmático (e), localizado entre o Maciço de Goiás e a Faixa Brasília. Segundo estes autores, dentro do Arco Magmático ocorrem seqüências vulcano-sedimentares, de idade neoproterozóica, como as de Sanclerlândia, Bom Jardim de Goiás, Mara Rosa e Porangatu, além de ortognaisses subordinados. De acordo com os autores supracitados, estes terrenos são típicos de arcos magmáticos, acrecionados no Neoproterozóico em consequência da obliteração do substrato ensimático que separa os crátons Amazônico e São Francisco. Esta unidade abriga ainda a seqüência vulcano-sedimentar de Chapada onde hospeda-se o depósito de cobre e ouro, objeto do presente estudo.

Blum (1995) ressaltou a importância de grandes elementos estruturais presentes na Província Tocantins, ativos durante o Ciclo Brasileiro. Estes elementos podem ser reunidos em três grupos principais: (i) inflexões estruturais; (ii) falhas de empurrão com vergência para o Cráton do São Francisco e (iii) Lineamento Transbrasiliano. Dentre as falhas de empurrão presentes na Província Tocantins, normalmente vergentes para o Cráton do São Francisco, o autor destacou a importância da Falha do Rio dos Bois (Arantes et al. 1991), a qual se estende a região de Peixe (TO), passando por Mara Rosa e Chapada (GO) e chega até Crixás (GO), percorrendo mais de 300 km no Maciço de Goiás. Blum (1995) também citou o Lineamento

Transbrasiliano como significativo elemento estrutural da província, com direção principal NE-SW e caráter dextral (Costa & Hasui 1988).

### 3.6.2 Principais Unidades Geológicas da Área Estudada

#### 3.6.2.1 Terrenos granito-*greenstone* do norte de Goiás

Os principais estudos (Barbosa et al. 1969) sobre os terrenos pré-cambrianos do Maciço de Goiás, situado na Província Tocantins, consideraram os “extremos derrames básicos e ultrabásicos na base do Grupo Araxá”, incluindo os atuais komatiitos, como integrantes de seqüências ofiolíticas.

O primeiro reconhecimento de terrenos tipo granito-*greenstone* em Goiás deve-se a Danni & Ribeiro (1978), que identificaram, em Crixás, Pilar de Goiás, Hidrolina e Guarinos, seqüências vulcano-sedimentares com características de *greenstone belt*, agrupando-as sob a denominação de Grupo Pilar de Goiás. A identificação de textura spinifex em derrames ultramáficos nas seqüências vulcano-sedimentares de Crixás (Saboia 1979) e de Hidrolina (Danni et al. 1980) corroborou sua classificação como do tipo *greenstone belt*.

Os *greenstones* acima mencionados ocorrem como faixas estreitas, alongadas na direção geral NNW-SSE (figura 3.5), e separadas por terrenos constituídos, predominantemente, por tonalitos e granodioritos, com enxames de diques máficos (Danni et al. 1986, Kuyumjian 1990, Jost et al. 1994). A estratigrafia geral, a grosso modo, é semelhante aos demais *greenstones* do mundo: porção inferior constituída essencialmente por vulcânicas ultramáficas komatiíticas, porção intermediária com predomínio de basalto almofadados e, na porção superior sedimentos químicos e detríticos, por vezes com vulcanismo piroclástico associado (Saboia 1979, Kuyumjian 1986, Jost & Oliveira 1991). Intrusões tonalíticas, granodioríticas, thondjemíticas e graníticas estão presentes nos terrenos granito-*greenstone* de Goiás.

As associações minerais são praticamente constantes entre os *greenstones*, indicando regimes deformacionais e térmicos muito semelhantes para cada etapa de evolução. Associações minerais derivadas de alteração hidrotermal sinvulcânica e de eventos de deformação, equilibradas nas condições do fácies xisto verde, predominam amplamente (Kuyumjian 1981, Danni et al, 1986, Thomson 1987, Danni 1988, Pulz 1991, Magalhães 1991, Fortes & Nilson 1991 e Magalhães & Nilson 1993).

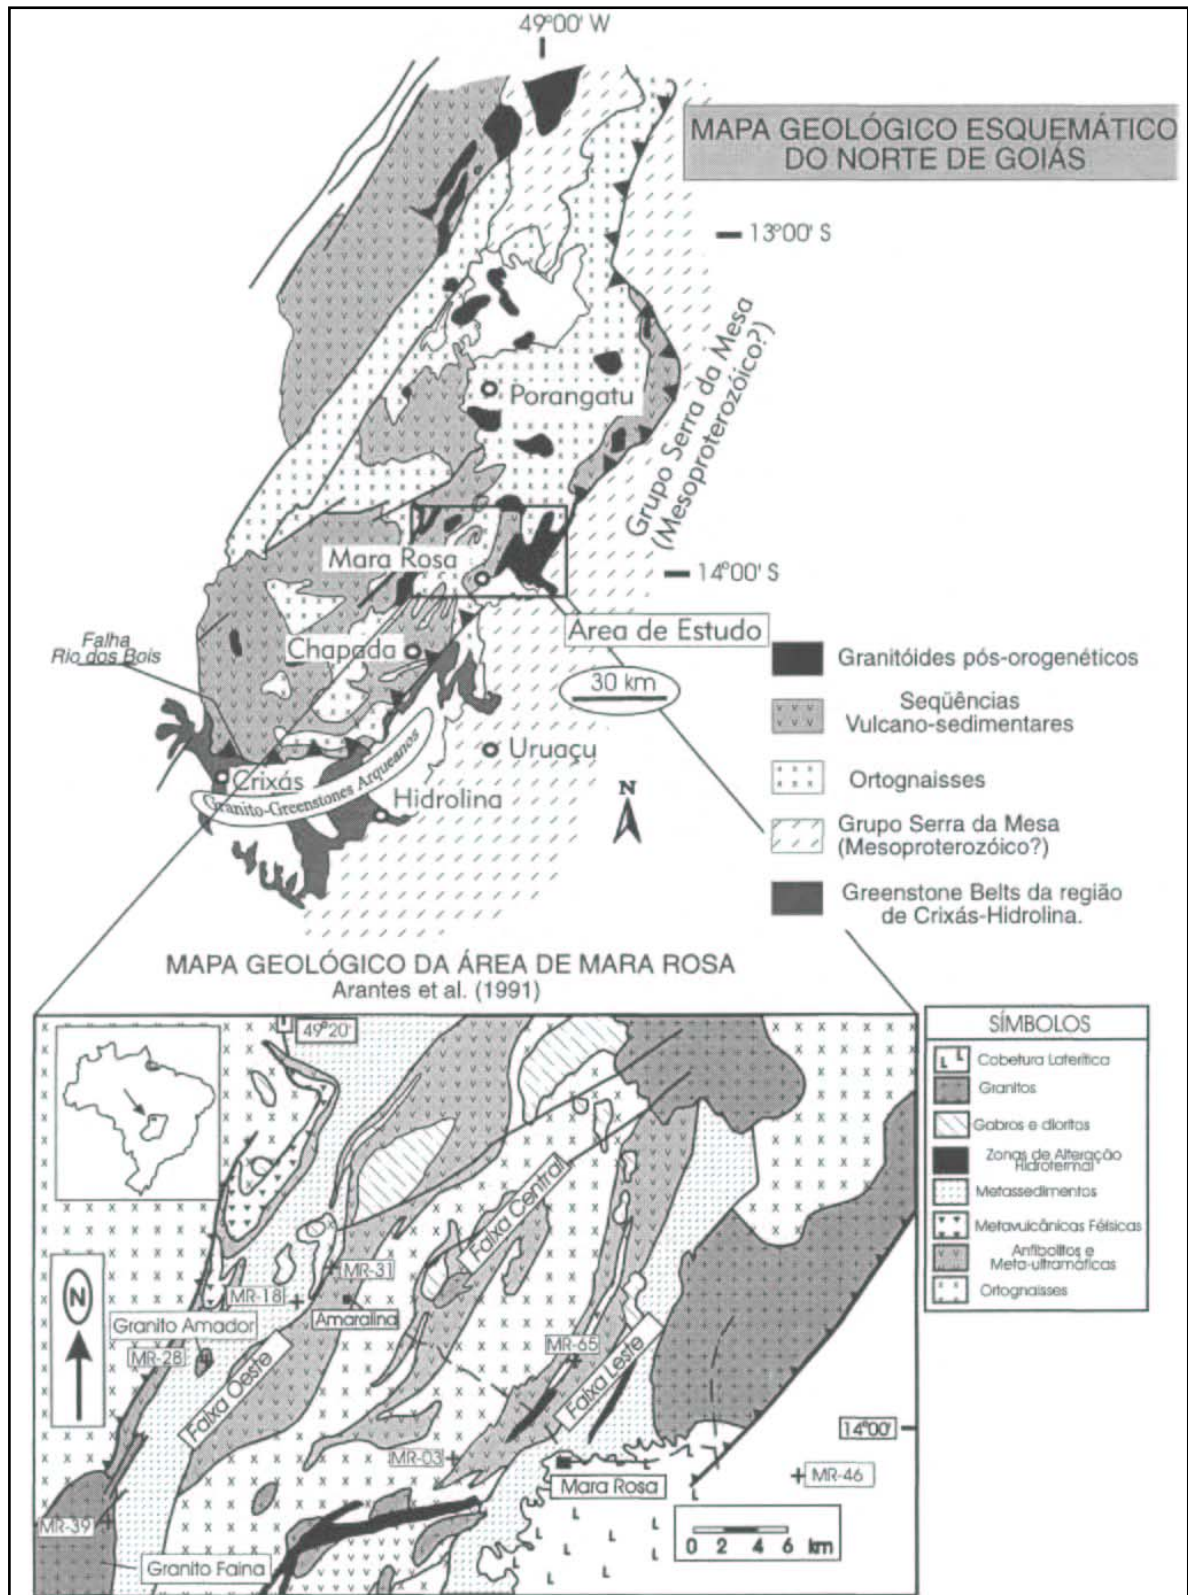


Figura 3.5 – Mapa geológico do norte de Goiás. Em detalhe a área da Seqüência Mara Rosa. (Viana et al., 1995)

Os dados geocronológicos referentes à formação dos *greenstones* da região de Crixás ainda são escassos. No entanto, é possível afirmar que os terrenos tipo *greenstone* do norte de Goiás datam do Arqueano, entre 2.9 e 2.7 Ga. (Tassinari & Montalvão 1980 e Arnoldt et al. 1989).

A mina de ouro de Crixás, atualmente lavrada pela Mineração Serra Grande S.A., é um importante exemplo de depósitos associados e do potencial mineral dos terrenos *greenstone* do norte goiano.

### 3.6.2.2 A Seqüência Mara Rosa

Definida originalmente por Ribeiro Filho (1981), a Seqüência Mara Rosa é formada por anfibolitos (basaltos e andesitos), micaxistos e quartzitos feldspáticos, metamorfizados em condições de fácies anfibolito a granulito. De acordo com Arantes et al. (1991), a Seqüência Mara Rosa é formada por três faixas de metassedimentos e metavulcânicas, orientadas na direção NE-SW com mergulho para NW (figura 3.5). Segundo o mesmo autor, todas estas rochas foram intrudidas por corpos gabróicos e graníticos, estando todo o conjunto metamorfizado em condições de fácies xisto verde superior a anfibolito superior.

Arantes et al. (1991) definiram a Faixa Leste com espessura em torno de 6.000 m, dividida em quatro subunidades. A primeira, Unidade Amaro Leste, consiste de metassedimentos, predominantemente grauvacas, com intercalações de tufos máficos, e perfaz uma espessura da ordem de 3.000 m. É sobreposta pela Unidade Arantes, a qual é constituída por tufos máficos a intermediários, com intercalações de grauvacas, vulcânicas félsicas e chert, e possui espessura estimada em 1.300 m. A Unidade Posse tem aproximadamente 400 m de espessura e é composta por tufos félsicos e lapilli-tufos de textura gnáissica e composição variando entre quartzo-latito e riolito, estes últimos hospedando a mineralização aurífera do depósito Posse. Por fim, a Unidade Caramolas consiste de tufos e derrames máficos, com intercalações de rochas vulcânicas/sub-vulcânicas félsicas e espessura aproximada de 1.200 m.

A Faixa Central é composta por vulcânicas máficas com intercalações de lentes ultramáficas, folhelhos e formações ferríferas e, em menor quantidade, vulcânicas félsicas e arenitos feldspáticos. O metamorfismo atinge o fácies anfibolito. Ocorre ainda um horizonte rico em quartzo, mica e barita o qual hospeda o depósito aurífero Zacarias (Arantes et al. 1991).

Ainda segundo Arantes et al. (1991), a Faixa Oeste é constituída por vulcânicas máficas e ultramáficas na base, sobreposta por vulcânicas félsicas e grauvacas com chert e formações ferríferas. O metamorfismo é o mais alto dentre as três faixas e atinge o fácies anfíbolito superior.

Viana (1995) descreveu a presença de diversos corpos intrusivos na seqüência metamórfica, os quais possuem composição dominante granítica ou diorítica. Estudos geocronológicos e geoquímicos realizados pela autora propuseram uma evolução ensimática para as rochas da Seqüência Mara Rosa, em ambiente de arcos de ilhas primitivos. Ortognaisses e metavulcânicas félsicas mostraram idades U-Pb entre 862-856 Ma. Antes da nucleação da deformação brasileira teve lugar a subducção de litosfera oceânica e geração de crosta continental juvenil. Isto é indicado pelo conteúdo de elementos maiores e traço de ortognaisses, similares aos de rochas graníticas de arco vulcânico em ambiente pré-colisional.

Corpos sintectônicos à deformação principal foram datados em aproximadamente 630 Ma (U-Pb em diorito). Também titanitas em metavulcânicas indicaram recristalização das mesmas há 632 Ma. Viana (1995) propôs a acresção dos terrenos de arco à crosta continental durante o Brasileiro. A mesma autora postula, ainda, a intrusão de corpos graníticos a gabro dioríticos pós-tectônicos (ca. 500 Ma., Rb-Sr em rocha total) alojados na crosta quando do soerguimento pós-orogênico.

### 3.6.2.3 A Seqüência Chapada

Machado (1981) referiu-se à Seqüência Chapada (gnaisses, migmatitos e seqüências vulcano-sedimentares), como a parte superior de terrenos arqueanos tipos *greenstone belts*. Entretanto, Ribeiro Filho (1981) argumentou que as rochas pertencentes à seqüência vulcano-sedimentar estão sobrepostas aos *greenstones*.

Kuyumjian (1989) destacou que a feição tectônica mais importante da região de Chapada (GO) é a Falha do Rio dos Bois (figura 3.5) com direção NE-SW, a qual separa a leste uma seqüência vulcano-sedimentar, que o autor compara àquela que aflora ao sul dos *greenstones* da Janela Arqueana, e a oeste uma seqüência dominada por metassedimentos e anfíbolitos, os quais podem ser efetivamente denominados de Seqüência Chapada.

O autor acima divide a Sequência Chapada em dois grupos: (i) Grupo Metassedimentar e (ii) Grupo dos Anfíbolitos. O Grupo Metassedimentar (i) por sua vez foi subdividido em duas

unidades: Unidade Metassedimentar de Leste, composta por metarenitos, xistos a estaurolita e cianita, biotita xistos feldspáticos, formações ferríferas bandadas, granada mica xistos, anfibólio xistos e metachert, e Unidade Metassedimentar de Oeste, constituída por estaurolita mica xistos e biotita xistos feldspáticos. O Grupo dos Anfibolitos (ii) abriga epidoto anfibolitos e granada anfibolitos intercalados com sedimentos em pequena quantidade e clinopiroxênio anfibolito com pequenas intercalações de formações ferríferas bandadas. Ocorrem ainda corpos intrusivos de tonalitos, granodioritos, gabro, hornblendito e piroxenito, e diques cortando a foliação principal da seqüência que apresenta direção NE-SE e mergulho para NW. Este autor relatou também a ocorrência de mineralização de ouro e cobre em horizonte hidrotermal (depósito de Chapada).

Kuyumjian (1989), em detalhado estudo geoquímico destas rochas, propôs sua evolução em ambiente ensimático, gradando de arco de ilha imaturo a bacia tipo retroarco. Segundo o autor, as concentrações de elementos maiores, traço e terras raras dos anfibolitos são características de basaltos de arco oceânico. Os granitóides intrusivos na seqüência mostram fonte ultramáfica mantélica ou eclogítica, com componente crustal pouco importante quando de sua evolução. Isto indica uma origem similar para os granitóides, metabasaltos e metabasaltos andesíticos. Kuyumjian, 1989, postulou ainda que um olivina gabro, observado na área, pode ser um equivalente plutônico das vulcânicas de arco da região de Chapada.

Como pode ser observado e de acordo com os dados aqui apresentados, existe forte correlação entre os terrenos da Seqüência Mara Rosa e aqueles da Seqüência Chapada. Estes podem ser caracterizados como participantes de um amplo sistema de arco intraoceânico, desenvolvido durante o Neoproterozóico, no Ciclo Brasileiro (Arantes et al., 1996).

#### **3.6.2.4 A Seqüência Santa Terezinha**

Consiste numa seqüência vulcano-sedimentar aflorante imediatamente a norte da Janela Arqueana do Norte de Goiás e a oeste das seqüências Chapada e Mara Rosa (Arantes et al, 1996) (figura 3.6). Já foi correlacionada à cobertura sedimentar dos terrenos tipo *greenstone belt* desta janela (Danni & Ribeiro 1978, Machado 1981), ou às seqüências Porangatu e Mara Rosa (Arqueano a Paleoproterozóico) (Souza & Leão Neto, 1984), ou às seqüências Jucelândia, Coitezeiro e Palmeirópolis (Ribeiro Filho, 1981).

A presença de textura tipo spinifex, o quimismo compatível com os komatiitos de Crixás e finas intercalações de metassedimentos em vulcânicas levaram Costa (1986) a atribuir características komatiíticas à Seqüência Santa Terezinha.

Pimental & Fuck (1992) situaram a Seqüência Santa Terezinha dentro do arco magmático neoproterozóico (900 a 600 Ma.). Entretanto, Biondi & Poidevin (1994) dataram o hidrotermalismo principal da seqüência em ca. 2.960 Ma., correlacionando-a aos *greenstones* imediatamente a sul.

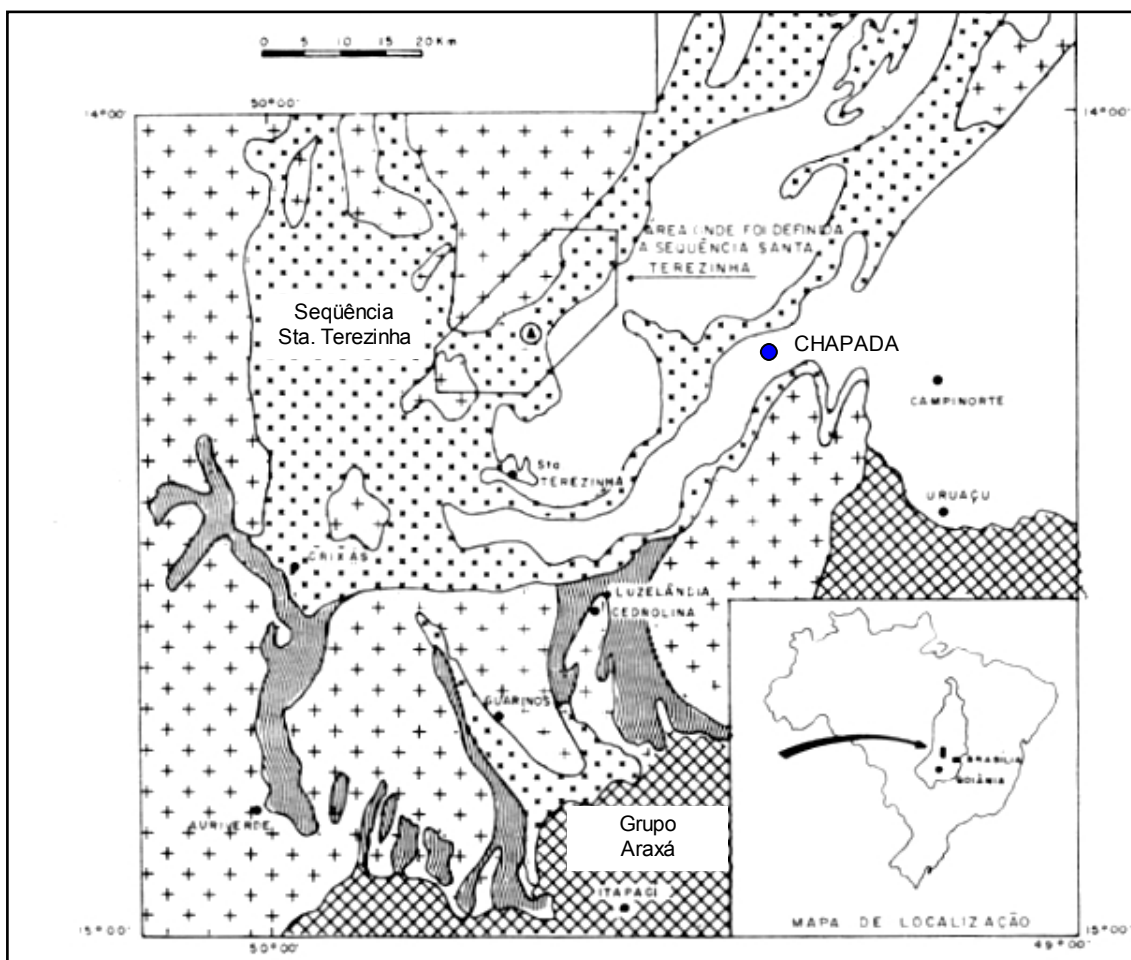


Figura 3.6 - Mapa geológico esquemático localizando a Seqüência Santa Terezinha e Grupo Araxá na região de Chapada. (modificada de Costa et al., 1986)

### 3.6.2.5 Grupo Araxá

Definido inicialmente por Barbosa (1955), o Grupo Araxá é composto essencialmente por micaxistos e quartzitos, além do vulcanismo bimodal intercalado, e tem seção tipo nas

proximidades da cidade de Araxá (MG). Schobbenhaus et al. (1975) separaram duas unidades distintas no Grupo Araxá: (i) Unidade Inferior - micaxistos granatíferos e a duas micas, e quartzitos micáceos, ocorrendo ainda intercalações de xistos carbonosos; (ii) Unidade Superior - calcoxistos com lentes calcáreas e intercalações de quartzitos. Fuck & Marini (1981) descreveram este grupo como constituído por, da base para o topo, gnaisses bandados, xistos feldspáticos e micaxistos. A literatura relativa ao Grupo Araxá relata metamorfismo em condições de facies xisto verde, podendo chegar a anfíbolito.

A continuação dos estudos geológicos no estado de Goiás implicou na ampliação da área de abrangência do Grupo Araxá até os limites com o estado Tocantins. Infelizmente, as pequenas escalas de mapeamento no norte de Goiás, em especial na região da Folha Bonópolis (49° 30'W - 50°00'W / 13°30'S - 14°00'S), não permitiram uma melhor caracterização das rochas atribuídas a este Grupo. Sabe-se inclusive que os terrenos tipo *greenstone* da região de Crixás e as rochas das seqüências Mara Rosa e Chapada já foram interpretadas como pertencentes ao Grupo Araxá (Barbosa et al. 1969). A figura 3.6 localiza a ocorrência do Grupo Araxá na região de Chapada, segundo Costa et al. (1986).

A evolução tectônica e o posicionamento estratigráfico do Grupo também são objeto de grande controvérsia. Barbosa et al. (1969) relacionaram este grupo à evolução de um geossinclíneo no Brasil Central. Almeida (1971) propôs que a sedimentação, metamorfismo, deformação e magmatismo do grupo Araxá ocorreram no Ciclo Uruaçuano entre 990 e 1300 Ma. Posteriormente Pimentel et al. (1992) dataram um rocha interpretada como meta-riolito pertencente a este grupo. O método utilizado, U-Pb em zircão, fornece idade de cristalização igual a 794 ± 10 Ma. Entretanto, não se pode afirmar qual é o posicionamento estratigráfico do possível meta-riolito dentro do Grupo Araxá. Strieder (1993) propôs que o Grupo Araxá, na região de Abadiânia (GO), tenha se formado de uma calha de subducção, com uma associação petrotectônica referente a uma melange ofiolítica. Winge (1995) manteve o posicionamento estratigráfico do Grupo Araxá entre as unidades referente ao Paleo-Mesoproterozóico, juntamente com os Grupos Araí, Canastra e Serra da Mesa, este último equivalente ao Grupo Araxá na parte norte da Província Tocantins (Marini et al. 1981).

### 3.6.2.6 Terrenos Granito-Gnaíssicos

Devido a pequena escala de mapeamento de algumas regiões de Goiás, muitas rochas granito-gnáissicas ainda se encontram sob a denominação de Pré-Cambriano Indiferenciado ou denominação similar. Almeida (1967) considerou os granito-gnaisses como pertencente ao Complexo Basal Goiano, atual Maciço de Goiás. Já Barbosa et al. (1969) consideraram estas rochas como embasamento do Grupo Araxá. Schobbenhaus et al. (1975) atribuíram ao Pré-Cambriano indiferenciado rochas gnáissicas, desde graníticas e granodioríticas a tonalíticas principalmente; todas em condições de metamorfismo referentes aos fácies epidoto-anfibolito a granulito.

Parte das rochas relacionadas ao Pré-Cambriano indiferenciado (Schobbenhaus et al. 1975) refere-se aos complexos granito-gnáissicos da janela Arqueana do Norte de Goiás são denominados, de oeste para leste, Bloco da Anta, Complexo Caiamar, Bloco do Moqué e Domo de Hidrolina, cujas composições variam principalmente de granodiorito a tonalito (Vargas 1991). Além destes, os ortognaisses da Sequência Mara Rosa, já mencionados, também foram anteriormente classificados como Pré-Cambriano Indiviso.

## 3.7 Geologia local

### 3.7.1 Geologia do Depósito

A área do Projeto Chapada é parte de um grande sistema de faixas móveis com uma complexa história de deformações polifásicas, de idade Proterozóica (ciclo Brasileiro-Pan-Africano), que produziram transformações de diferentes intensidades em várias fases, dificultando as correlações entre as diversas unidades geológicas, o que também, se reflete numa ampla variedade de idades, obtidas nas datações geocronológicas. Este fato leva diversos autores a diferentes interpretações quanto à idade, o posicionamento, os controles estruturais e mesmo quanto às potencialidades destas unidades geológicas, como pode ser deduzido das informações regionais anteriormente citadas.

As sequências Chapada e Mara Rosa são consideradas neste estudo, como uma única unidade geotectônica, devido a correlações espaciais, litológicas e geocronológicas, sendo aqui, englobadas na denominação de Sequência Chapada - Mara Rosa, já que as litologias ocorrentes

em Chapada representam uma extensão para sul da Seqüência Mara Rosa (Arantes et al,1996).

Embora mais estudada por apresentar ocorrências minerais importantes, notadamente cobre e ouro, a Seqüência Chapada-Mara Rosa tem ainda grandes lacunas de dados estruturais, petrológicos e geocronológicos necessários a uma definição mais confiável de sua evolução.

Aflora na região de Chapada uma seqüência vulcano-sedimentar, metamorfizada no fácies anfibolito alto, deformada, fortemente hidrotermalizada, o que dificulta a identificação do protolito. As litologias observadas no depósito de Chapada são portanto produtos de metamorfismo, deformações e alterações hidrotermais de rochas vulcano-sedimentares preexistentes. Originam, em geral, uma espessa cobertura de solo laterítico ou lateritas, com poucos afloramentos o que dificulta muito o mapeamento de superfície.

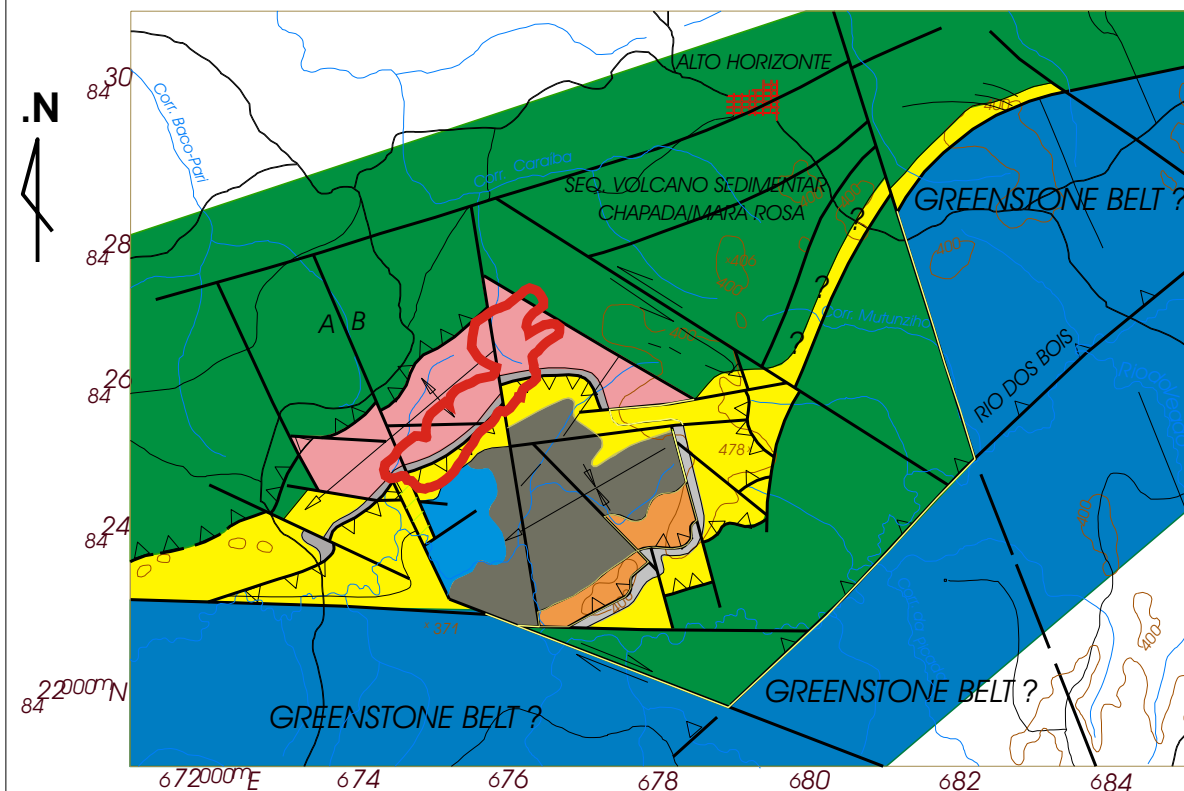
A Seqüência Chapada-Mara Rosa é composta, na área do depósito, por uma sucessão de rochas metavulcânicas ultramáficas-máficas e ácidas (metapiroxenitos, metabasaltos, metadacitos e metariodacitos), com intercalações de sedimentos grauvaquianos e pelíticos, e, secundariamente, sedimentos químicos. Ocorrem ainda rochas metatufáceas, ácidas, intermediárias e máficas. Esta seqüência é atualmente representada por piroxênio-anfibolitos, anfibólio xistos, biotita-feldspato xistos, epidoto anfibolitos, muscovita-xistos piritosos e metatufo ácido. Os xistos têm comumente a cianita como mineral de destaque, originando cianita-anfibólio xistos, cianita-biotita-feldspato xistos, cianita-muscovita xistos piritosos. Outros minerais freqüentes são granada, estauroлита, cordierita e silimanita. Estas rochas, quando apresentam certo bandamento, podem ser classificadas como gnaisses. Intrudem a seqüência diques pegmatíticos e anfibolíticos e um corpo tonalítico a sudeste do depósito. A figura 3.7 apresenta o mapa geológico local simplificado, com os principais litotipos.

A estratigrafia do depósito de Chapada apresenta, da base para o topo (de oeste para leste), o seguinte empilhamento (figura 3.8):

1. Unidade Metamáfica - Pacote de rochas metamáficas ( metabasaltos ) e lentes ou diques de metaultramáficas anfibolitizadas:

Anfibolitos provenientes de rocha máfica: apresentam granulação fina, coloração esverdeada, foliação discreta, compostos por hornblenda (60%), biotita (7%), plagioclásio(1%), quartzo (1%), epidoto e titanita.

## DEPÓSITO DE CHAPADA MAPA GEOLÓGICO



### LEGENDA

PROTEROZÓICO SUPERIOR  
SEQUÊNCIA VULCANO-SEDIMENTAR  
CHAPADA/MARA ROSA

- TONALITO
- EPIDOTO-ANFIBOLITO,  
HORNBLENDA GNAISSES
- XISTOS MUSCOVITA
- QUARTZITO COM PIRITA  
(HIDROTHERMALITO)
- META-TUFO INTERMEDIÁRIO A ÁCIDO
- FELDSPATO BIOTITA XISTOS  
COM MUSCOVITA
- ANFIBOLITO (METABASALTO)

ARQUEANO

- GREENSTONE BELT ?
- FALHA DE EMPURRÃO
- FALHA COM DESLOCAMENTO  
HORIZONTAL RELATIVO
- FALHA NORMAL, BLOCO ALTO(A)
- ANTICLINAL
- SINCLINAL

Ⓢ CONTORNO DO DEPÓSITO  
CHAPADA (Cu/Au)



**Figura 3.7 - Mapa geológico local da Sequencia Chapada.**  
(modificado Mineração Alonte, 1997)

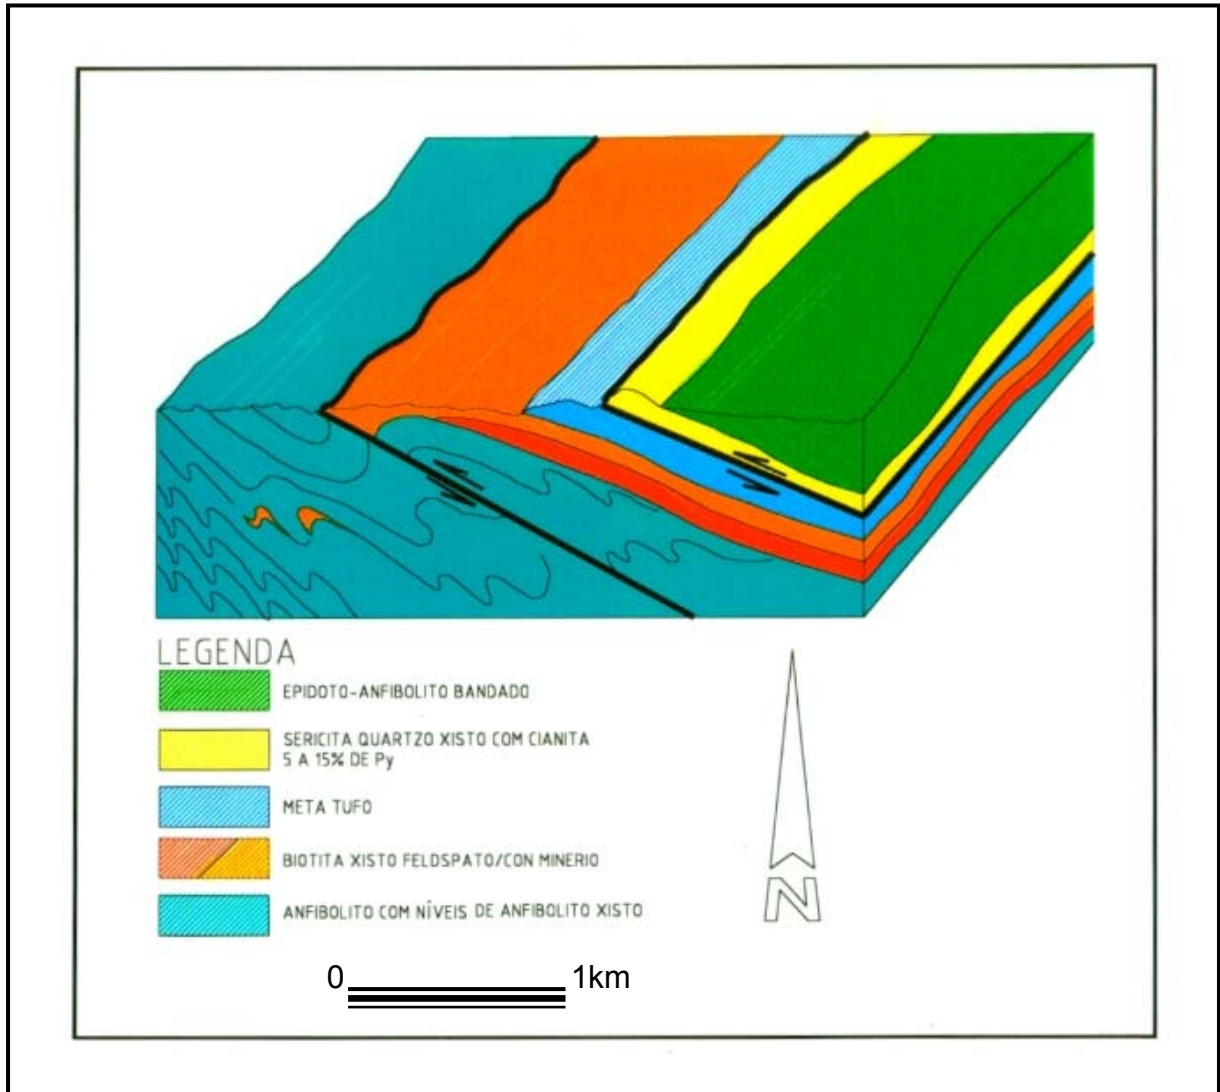


Figura 3.8 – Bloco diagrama mostrando o empilhamento estratigráfico e macro-estruturas do depósito de Chapada. (Mineração Maracá)

Anfibolitos provenientes de rocha ultramáfica: apresentam granulação grossa, cor verde escuro, pouco orientado, e compõe-se de hornblenda (90%), clorita (5%), plagioclásio (1%), epidoto (2%), zeólito (1%) e titanita (1%).

2. Unidade Metavulcânica ácida - Pacote de rochas metavulcânicas ácidas (metadacitos e metariodacitos) com intercalações de metavulcânicas básicas, metassedimentos (?) grauvaqueanos e pelíticos, e metassedimentos químicos (metachert). É a unidade de maior importância por ser a hospedeira da mineralização, que por sua vez encontra-se praticamente confinada aos níveis de rochas com composição dacítica e riodacítica. Este pacote apresenta as maiores variações petrológicas em função da diversidade dos litotipos originais e da maior intensidade de deformações e processos de alteração hidrotermal a que foi submetido. Nos estudos petrográficos de Marchetto (1996) essas rochas foram separadas em vários grupos de acordo com a mineralogia e textura apresentados, aqui agrupados de forma simplificada:

Grupo 1 - Rochas metavulcânicas ácidas (metadacitos-metariodacitos):

biotita-muscovita xistos, biotita-muscovita xistos feldspáticos, epidoto-biotita xistos feldspáticos. Estas rochas, foram cisalhadas e posteriormente recristalizadas (recristalização pós-tectônica). Mostram-se afetadas por intensa alteração hidrotermal (biotitização, muscovitização e silicificação), com enriquecimentos de sulfetos e ouro. A maioria da muscovita e biotita presentes são produtos de alteração hidrotermal em zona de cisalhamento. Foram observados nestas rochas cristais de plagioclásio intensamente recristalizados em fenocristais provavelmente relictos de textura vulcânica original de rochas metavulcânicas ácidas de composição dacítica.

Grupo 1B - Rochas metavulcânicas ácidas (metadacitos?):

Biotita-plagioclásio gnaisses e muscovita-plagioclásio gnaisses. Estas rochas são similares às do Grupo 1, mas estão intensamente recristalizadas, não preservando relictos de textura vulcânica original.

Grupo 1C - Rochas metavulcânicas ácidas (metadacitos?):

Cianita-biotita-plagioclásio gnaisses. Nesta rochas, a presença de porfiroclastos de plagioclásios zonados são sugestivas indicações de origem vulcânica para este litotipo. A cianita encontra-se parcial ou totalmente sericitizada.

Grupo 2 - Rochas metavulcânicas riodacíticas (?):

Biotita-microclínio gnaisses. Encontram-se intensamente recristalizadas e as texturas relictuais de rochas vulcânicas estão pouco preservadas.

Grupo 3 - Rochas metassedimentares (?): foram interpretadas no estudo petrográfico como de origem metassedimentar (pelitos), mas se consideradas as intensas trocas químicas que se realizaram neste pacote rochoso pode-se concluir pela possibilidade de gerar, a partir das rochas anteriormente descritas, estes mesmos litotipos finais. Kuyumjian (1998) interpreta uma paragênese hornblenda-epidoto-quartzo-cianita-estaurolita-plagioclásio-rutilo, comumente atribuída a anfíbolitos derivados de metasedimentos, como orto-anfíbolitos resultantes do metamorfismo de basaltos metassomatizados. Esta interpretação levaria a se concluir nesta unidade, pela existência de um pacote único de metavulcânicas dacíticas-riodacíticas, afetadas com diferentes intensidades, pelo processo de alteração hidrotermal.

Grupo 3A - Rochas à biotita /cianita:

Biotita-cianita xisto feldspático, clorita-biotita-cianita xisto feldspático, estaurolita-hornblenda-biotita-cianita xisto. Caulinização do plagioclásio é a alteração hidrotermal mais freqüente. Ocorrem ainda sericitização da cianita e cloritização da biotita.

Grupo 3B - Rochas à muscovita / cianita:

Muscovita-cianita xisto feldspático e clorita-muscovita xisto feldspático. Estas rochas foram intensamente hidrotermalizadas, ocorrendo principalmente sericitização. São similares às rochas do Grupo 2, mas com intensidade maior de alteração hidrotermal e sem biotita. A cianita foi, parcial ou totalmente, substituída pela sericita.

Grupo 3C - Rochas à cordierita, muscovita e cianita:

Cordierita-cianita xisto, cordierita-muscovita-cianita xisto e muscovita-clorita-cianita xistos. A presença de cordierita sugere um metassomatismo com enriquecimento de magnésio. As

alterações hidrotermais nestas rochas foram intensas, originando grandes cristais não orientados de cianita.

Grupo 3C1 - Rochas à hornblenda, antofilita, biotita e cianita:

Hornblenda-antofilita-clorita-cianita-biotita xistos, biotita-antofilita-clorita-cianita-hornblenda xistos feldspáticos, antofilita-hornblenda-biotita xistos. Usualmente a antofilita forma um núcleo nos cristais de hornblenda, sugerindo uma origem posterior por metassomatismo rico em magnésio, chegando a criar verdadeiras “camadas” de antofilita anfíbolito não orientado ou pouco orientado.

3. Unidade Tufácea - trata-se da capa do minério de cobre e ouro de Chapada, sobrepondo-se à Unidade de Metavulcânicas ácidas. Ocorrem metatufos com composição variando de ácida a intermediária. Os termos ácidos são típicas rochas vulcanoclásticas com texturas relictas bem preservadas, assim como fragmentos de rocha e plagioclásio, além de porfiroclastos de quartzo (“olhos” de quartzo). A cianita está comumente presente.
4. Unidade Quartzo-piritosa – constitui unicamente um “hidrotermalito” composto por quartzo ( 55% ), pirita ( até 40% ), fucsita ( 5% ), e traços de carbonato, zoizita e clorita. É comum a presença de cianita e muita muscovita nesta rocha, dando origem a cianita-muscovita-quartzo xistos piritosos. Petrográficamente foi classificado como metachert, entretanto os trabalhos de campo na área de Chapada, e outros anteriormente efetuados na região de Mara Rosa por Machado (1981) e Arantes ( comunicação verbal), apontam para produtos da alteração hidrotermal de rochas anfíbolíticas.
5. Unidade Anfíbolítica bandada – são produtos do hidrotermalismo de metatufos com composição andesítica a basáltica, transformados em rochas bandadas com partes ricas em hornblenda e partes ricas em biotita. A muscovita e o epidoto presentes são pós-tectônicos e oriundos de alteração hidrotermal.
6. Intrusões tardi-tectônicas:
 

Tonalito – aflora como corpo circular na parte sul do depósito. A rocha exhibe granulação variável de fina a grosseira pouco orientada e compõe-se de hornblenda, plagioclásio e quartzo.

Pegmatitos – ocorrem sob a forma de diques pouco potentes intrudindo as unidades anteriores. A rocha exhibe estrutura maciça a pouco orientada, cor branca a rosada, e compõem-se de quartzo, feldspato potássico e muscovita esverdeada. Apresentam-se por vezes, alterados hidrotermalmente.

O manto de intemperismo do depósito atinge 25m a 30m de profundidade, gerando uma camada de solo delgada sobre crosta laterítica com até 2 m de espessura, que por sua vez sobrepõe-se a um horizonte saprolítico oxidado com até 25 m de espessura onde ocorreu lixiviação do cobre e enriquecimento supergênico do ouro. Entre o saprolito oxidado e a rocha são ocorre um horizonte de transição denominado “saprolito sulfetado” com até 5 m de espessura, caracterizado por rocha intemperizada com sulfetos preservados.

### 3.7.2 Geologia Estrutural

A área de Chapada apresenta uma complexa história tectono-estrutural, em que os eventos tectônicos de maior importância são as escamas de falhas de empurrão e falhas que as interceptam, por se relacionarem diretamente com as alterações hidrotermais e conseqüentes remobilizações que deram origem a mineralização ali presente, sendo ainda responsável pela própria forma e distribuição deste jazimento. As macro-estruturas locais estão plotadas no mapa geológico apresentado na figura 3.9 anteriormente citada.

O estudo detalhado da geologia estrutural do depósito de Chapada é dificultado pela carência de afloramentos. Entretanto as observações realizadas nos escassos afloramentos, testemunhos de sondagem e poços de pesquisa mostraram a direção N30°E como predominante na área, destacando-se um arcabouço de um anticlinório como a estrutura principal, com caimento suave (10°-20°) do eixo para SW e flancos mergulhando de 10° a 30° para NW e SE (figura 3.9). A foliação cataclástica prevalente com direção NE-SE é cortada por falhamentos N-15°/20 NW e N45°W. Na porção sul do depósito ocorre intersecção com falhas de trend E-W.

Uma seqüência de eventos estruturais podem ser sugeridos pelo relacionamento das estruturas observadas no depósito com a tectônica regional estudada por outros autores. O acamadamento (*So*) pode ser reconhecido em testemunhos de sondagem através, por exemplo, do contato entre tufos intermediários e máficos ou de aleitamentos composicionais gradacionais em tufos ácidos. Estas feições estão ligadas ao período de deposição e

sedimentação da seqüência vulcano-sedimentar. Embora  $S_0$  apresente-se predominantemente sub-horizantalizado, algumas dobras intrafoliais convolutas aparecem.

Sobrepondo-se a  $S_0$  observa-se a foliação  $S_n$ , definida pela orientação de minerais metamórficos como anfibólios e cianita, paralela a subparalela ao acamamento composicional. O desenvolvimento desta foliação ( $S_n$ ), está relacionada a um esforço  $D_n$ , de sentido NW para SE. Associada a progressão do esforço ( $D_n$ ) aparece uma foliação moderada a forte  $S_{n+1}$  definida pela geração da biotita, assim como um estágio inicial de geração de muscovita e sericita, subparalela a  $S_n$ .

A foliação  $S_{n+1}$ , embora não se encontre bem desenvolvida em toda a área do depósito, está diretamente relacionada as zonas de cisalhamento de baixo ângulo (escamas de empurrão) e reflete a fase deformacional relacionada com a mineralização de cobre-ouro de Chapada. Estas zonas de cisalhamento de baixo ângulo podem ter surgido devido a diferenças de resistência entre os estratos presentes. Os fluidos hidrotermais mineralizantes aproveitaram-se para percolar estes “canais” e precipitar o minério nos horizontes estruturais e litológicos propícios associados às rochas metadacíticas, metariodacíticas e metassedimentos. Ainda associada a este esforço, as zonas de cisalhamento de baixo ângulo e o pacote litológico já hidrotermalizado foram dobrados. Localizadamente a foliação ( $S_{n+1}$ ) mostra-se extremamente crenulada, crenulação esta gerada por cisalhamentos direcionais N30°E e N40°W.

As zonas de cisalhamentos tangenciais e foliações  $S_{n+1a}$  com atitude N30°-45°E / 30°-45°NW são de caráter regional com vergência marcante para SE.

Falhamentos normais N 5°W a N 15°W cortam as demais estruturas locais, chegando a configurar um pequeno “graben” no depósito de Chapada, evidenciado pela deslocamento do nível mineralizado (figura 3.9).

Na área do depósito de Chapada, a seqüência vulcano-sedimentar Chapada-Mara Rosa pode ser vista como uma grande lasca ou “cunha” empurrada sobre a unidade ocorrente a leste (*greenstone belt*?).

### 3.7.3 Metamorfismo

O metamorfismo da Seqüência Chapada Mara Rosa encontra-se predominantemente no fácies anfibolito alto, gerando até migmatitos, gradando localmente para fácies xisto verde. Em



determinadas posições estruturais, são encontrados termos excepcionalmente preservados guardando ainda as estruturas e texturas primárias da rocha, o que demonstra a heterogeneidade da deformação e metamorfismo.

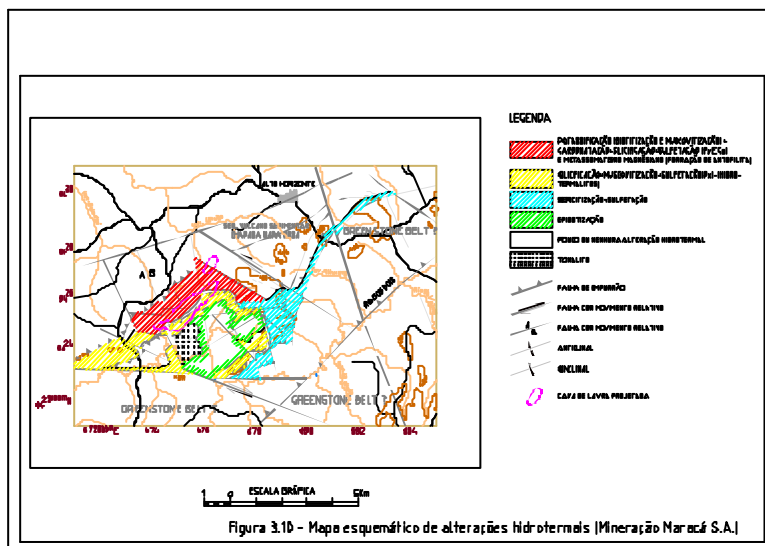
Richardson et al (1986) estimaram as condições do “pico metamórfico” em torno de 650° C e 7,5 kb, equivalentes à aproximadamente 22 km de soterramento. A estas temperatura e profundidade foi formada a assembléia mineral cianita-estaurolita-granada. A cianita se apresenta como grandes cristais porfiroblásticos alongados acompanhando a foliação, mesmo quando esta se apresenta dobrada e crenulada. Encontra-se na maioria das vezes, como pseudomorfos, total ou parcialmente sericitizados. A granada ocorre associada ou não à cianita, tanto em rochas de origem sedimentar como nas vulcânicas. A biotita está presente na maioria dos xistos do depósito e pode originar em parte, não do metamorfismo progressivo, mas de alteração hidrotermal.

Efeitos de metamorfismo retroprogressivo estão impressos nas rochas da seqüência de Chapada, sob a forma, principalmente, de cloritização de biotita e granada. As condições de retrometamorfismo foram estimadas em 460° C e 5 kb (Kuyumijian, 1990). Ainda segundo o mesmo autor, além dos metamorfismos regionais, as rochas de Chapada foram também afetadas por um primeiro metamorfismo de baixo grau, conseqüência de circulação hidrotermal de água do mar (espilitização), sugerido pelo enriquecimento em Na<sub>2</sub>O e empobrecimento em K<sub>2</sub>O, identificados em amostras de anfibolitos.

#### **3.7.4 Alterações hidrotermais**

Os efeitos provocados por alteração hidrotermal nesta área são dos mais expressivos, quer seja na formação do depósito mineral, quer seja nas transformações impressas nas litologias. Os processos de alteração hidrotermal ocorreram de forma mais intensa em posições estruturais favoráveis (escamas de falhas de empurrão). As principais alterações hidrotermais detectadas nessas rochas são: potassificação (sericitização, biotitização, muscovitização e caulinitização), silicificação, sulfetação, carbonatação, epidotização, cloritização e enriquecimento em magnésio (formação de antofilita e cordierita). Em geral estas alterações ocorrem associadas, porém com predomínio de um ou outro tipo (figura 3.10).

Na porção oeste do depósito, o anfibolito posicionado como lapa do corpo mineralizado apresenta-se bastante homogêneo, não mostrando efeitos extensivos de alteração



hidrotermal, apenas biotitização e sulfetação (piritização) localizadas. Kuyumjian (1998) descreve nessa área a ocorrência de cianita-estauroлита anfíbolitos gerados a partir de ortoanfíbolitos submetidos a processos hidrotermais com enriquecimento relativo de alumínio e água, e lixiviação de cálcio, seguido por metamorfismo regional em fácies anfíbolito, em condições de pressão mais elevadas.

Na porção central, onde se encontra a mineralização, as rochas metavulcânicas dacíticas e riodacíticas, bem como metassedimentos apresentam intensa variação mineralógica devido às transformações impostas pelo processo hidrotermal, tornando por vezes difícil a correlação litológica entre furos ou seções de sondagem. Quando ocorre o predomínio de uma ou outra alteração hidrotermal, este processo resulta em termos litológicos totalmente distintos. Localmente podem constituir “hidrotermalitos”, compostos de muscovita, quartzo e pirita (até 30%), e cianita. A principal alteração presente é a potassificação (biotitização e muscovitização) secundada por carbonatação, epidotização, sulfetação (pirita e calcopirita) e silicificação. Grande parte da biotita destas rochas provém da hidrólise da hornblenda (água + potássio).

Na parte leste do depósito, o metatufos ácido/intermediário (capa do corpo de minério) mostra-se afetado apenas em sua porção basal, e no geral preserva estruturas primárias de deposição. Na zona de capa do metatufos, os processos de alteração hidrotermal foram tão intensos que levaram à formação de “hidrotermalitos”, compostos de muscovita, quartzo e pirita (até 30%), e cianita, obliterando totalmente a rocha original, agora transformada em “pirita quartzito”, “muscovita-pirita-quartzo xisto” e “cianita-muscovita-pirita quartzito xisto”. Sobreposto ao “hidrotermalito” tem-se anfíbolito bandado, exibindo epidotização como alteração hidrotermal mais importante.

### **3.7.5 Mineralização e gênese**

O depósito de cobre e ouro de Chapada tem como principal hospedeira as rochas metavulcânicas ácidas (metadacitos e metariodacitos) transformadas em muscovita-biotita-feldspato xistos, seguido do anfíbólio biotita xisto feldspático e anfíbólio xistos, com cianita em quantidades variáveis. A mineralização aparece ainda, com menor expressão, na porção basal do metatufos considerado capa do minério principal.

A mineralização consiste principalmente de sulfeto disseminado, predominantemente calcopirita (0,5 a 5% da rocha), acompanhando a foliação mesmo quando esta encontra-se dobrada (figura 3.11). Ocorre ainda, remobilizações significativas em microfraturas, fraturas e nas zonas de falhamentos rígidos.

A calcopirita se apresenta como cristais anedrais alongados segundo a xistosidade da rocha hospedeira, comumente deformados, com dimensões variando de 0,010 mm a 15 mm predominando o intervalo 0,016-0,040 mm. Os estudos de seção polida revelam diferentes relações da calcopirita com outros sulfetos: calcopirita como inclusão na pirita, como agregados com magnetita e pirita, como cristais envolvendo a pirita e como cristais individuais. A calcopirita, muito freqüentemente, substitui a pirita, caracterizando uma cristalização posterior.




FIGURA 3.11 – Calcopirita concordante com a foliação da rocha (mica).  
(seção polida – aumento 235 X - IPT relatório no. 12.152)

A pirita é o sulfeto mais abundante, geralmente na proporção de 4 a 5:1 com a calcopirita, apresentando-se normalmente como cristais subedrais com dimensões variando entre 0,012 mm a 2,5 mm, predominando o intervalo 0,1-0,5 mm.

O ouro nativo não foi observado a olho nu, ocorrendo como grãos finos com tamanho máximo de 3  $\mu$  encapsulados na calcopirita ou como vênulas de tamanho 5  $\mu$  a 10  $\mu$  nos cristais de calcopirita e pirita (figura 3.12). A prata está presente em quantidades variáveis, associada ao ouro nativo.




FIGURA 3.12 – Ouro nativo (Au) em contato com calcopirita (cp), incluso em ganga transparente (escura). Cristais finos de pirita (py). 200x, luz plana refletida. (Marchetto, 1997)

A magnetita é o óxido mais abundante, porém com frequência inferior aos sulfetos de cobre, ocorrendo em grãos informes ou arredondados, subidiomórficos a idiomórficos, associado à calcopirita, pirita ou a ambas, o que é mais freqüente, formando uma associação trifásica (figura 3.13).




FIGURA 3.13 – Associação calcopirita-pirita-magnetita. (seção polida – aumento 235 X - IPT relatório no. 12.152)

Outros sulfetos estão presentes com menor frequência, tais como pirrotita, calcocita, bornita, molibdenita, galena, esfalerita e, em quantidade traço, a stibinita e cubanita. Esfalerita, bornita, galena, magnetita e molibdenita substituem calcopirita e a esfalerita substitui também a galena.

O minério pode ser visto como composto de dois corpos individuais, sendo o principal de forma tabular e o menor na forma de charuto. O corpo principal tabular exhibe dimensões da ordem de 3000 m de comprimento por 800 m de largura e 260 m de profundidade, e apresenta-se dobrado segundo uma antiforma aberta com flancos mergulhando suavemente para SE e NW e eixo mergulhando também suavemente para SW. O corpo menor situado a nordeste do principal apresenta dimensões aproximadas de 1500 m x 500 m x 150 m, e parece posicionar-se em eixo de dobra recumbente, o que lhe confere a forma de charuto, com *plunge* suave para SW (figura 3.14).

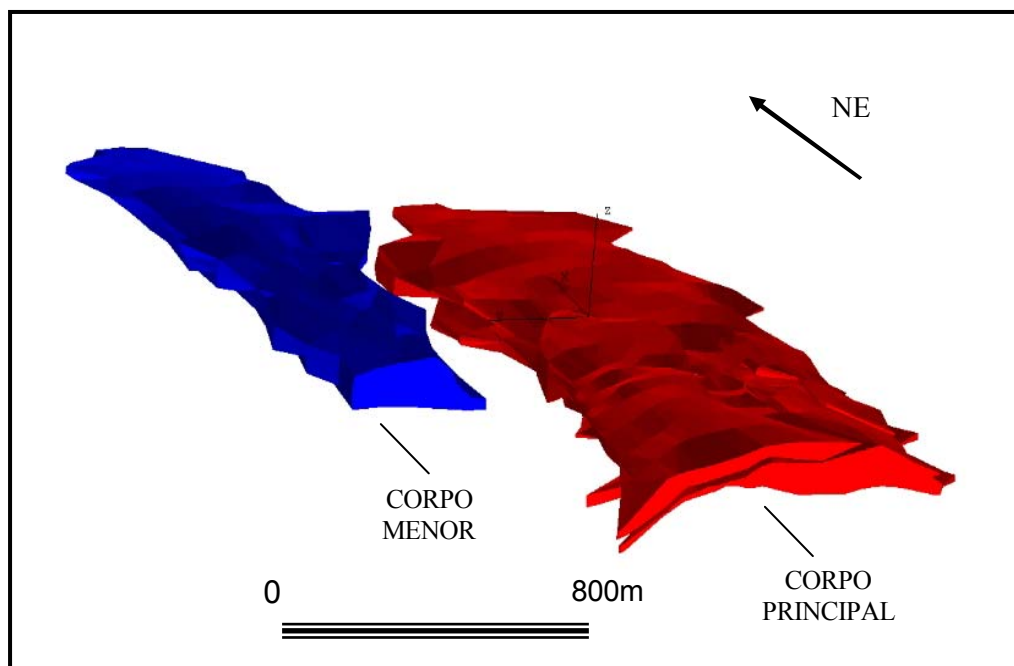


FIGURA 3.14 – Modelo tridimensional dos corpos mineralizados do depósito de Chapada.

Dentro dos corpos de minério ocorrem diversos níveis tabulares com teores de cobre e ouro mais elevados. A intensidade da mineralização é controlada por um conjunto de parâmetros da época de sua formação, que incluem o desenvolvimento de tensões heterogêneas (permeabilidade), a multiplicidade de rotas hidrológicas (porosidade) e a composição química da rocha e do fluido mineralizante.

A mineralização de cobre e ouro de Chapada é do tipo epigenético e está associada aos processos de alteração hidrotermal. Estes processos causaram profunda transformação na assembléia mineral metamórfica preexistente e indicam claramente que o principal estágio do processo hidrotermal e a precipitação da mineralização ocorreram pós pico metamórfico (metamorfismo regional, fácies anfíbolito alto a granulito). O cisalhamento acompanhado pelo principal estágio de alteração metassomática foi marcado pelo aparecimento da biotita gerada pela hidrólise de anfíbólio. Esta reação libera ferro que, combinado ao fluido hidrotermal rico em enxofre, geram a suíte sulfetada do depósito de Chapada. Devido a queda de fugacidade do enxofre no fluido mineralizante, o ouro foi precipitado conjuntamente. As zonas de cisalhamento de baixo ângulo formaram condutos permeáveis que permitiram a percolação dos fluidos e a subsequente precipitação do minério em horizontes litológicos propícios (metadacitos e metariodacitos).

Alterações hidrotermais posteriores e de mais baixa temperatura provocaram localizadamente remobilização parcial do minério e reconcentração ao longo de fraturas e zonas de falhamentos rígidos.

A maior parte dos estudos realizados sugere para o depósito um modelo tipo cobre pórfiro (Richardson et al., 1986) ou vulcanogênico hidrotermal exalativo (Silva, J.A et al., 1988 e Kuyumjian, 1991). O modelo proposto por Richardson et al. (1986) foi baseado em estudos de isótopos de enxofre na pirita e calcopirita e nas similaridades texturais, geoquímicas e de zoneamento das rochas encaixantes com depósitos de cobre pórfiro em arcos de ilha. Kuyumjian (1995) propôs um estágio metalogenético inicial envolvendo reações entre água do mar aquecida e basaltos da Sequência Mara Rosa, com lixiviação de metais das rochas basálticas e precipitação em zonas de alteração hidrotermal. Posteriormente, segundo o mesmo autor, o fluido hidrotermal originado de intrusões dioríticas pequenas lixiviou metais de rochas encaixantes, cuja precipitação enriqueceu a mineralização.

A despeito da atual controvérsia dos modelos metalogenéticos propostos, o depósito de cobre-ouro de Chapada pode então ser entendido como do tipo epigenético, ligado diretamente aos processos de alteração hidrotermal, associado a zonas estruturalmente favoráveis.

## CAPÍTULO 4. HISTÓRICO E INVENTÁRIO DOS DADOS DA EXPLORAÇÃO MINERAL

---

### 4.1 Histórico da exploração mineral e desenvolvimento do depósito de Chapada

Entre 1974 e 1975, a Mineração Serras do Leste Ltda., então subsidiária brasileira da Inco Limited (Canadá), realizou uma campanha de prospecção geoquímica regional para metais básicos, que permitiu, em um caso clássico, utilizando-se da avaliação de um programa de sedimentos de corrente, a identificação de uma área de interesse para cobre. Procedeu-se a prospecção geoquímica de solo em malha de 400 m x 50 m que resultou na individualização de uma anomalia com 290 ppm de cobre em média e aproximadamente 7 km de extensão. Confeccionou-se um mapa geológico em escala 1:10.000 e a malha de solo foi adensada para 200 m x 50 m.

De 1976 a 1979 seguiram-se os trabalhos de semidetalhe e detalhe desta área anômala, nos quais foram utilizados métodos diversos de geofísica aérea e terrestre, entre eles eletromagnetismo (EM) e indução polarizada (IP), que levaram à identificação do depósito, bem como, de uma outra importante zona anômala, situada a sul deste depósito.

Em 1976, a Eluma Indústria e Comércio S.A. associou-se ao projeto, com participação de 50 % dos interesses, porém a direção técnica permaneceu sob responsabilidade da Inco. Ainda no mesmo ano foi executado o primeiro programa de sondagem que consistiu de 46 furos diamantados denominados série “F”, com diâmetro AX e profundidades entre 50 a 60 m, seguidos de 6 furos com diâmetro BX denominados série “M”, totalizando cerca de 10.500 m de sondagem diamantada.

Entre 1976 e 1979 executou-se a segunda fase do programa na qual foram perfurados 78 furos diamantados com diâmetros BX e NX (série “M”), em malha de 200 m x 200m. Os testemunhos foram analisados para cobre, chumbo, zinco e, intermitentemente, para ouro. Definiu-se então, mineralização de cobre em uma área com 4.300 m de extensão e 400 m de largura.

Nesse mesmo período foram contratados os estudos de geologia e mina com o Instituto de Pesquisas Tecnológicas de São Paulo (IPT) e de beneficiamento do minério com o Centro de Pesquisas e Desenvolvimento (CEPED, Bahia). Os estudos de viabilidade

econômica preliminar levaram à identificação de uma reserva com 135 milhões de toneladas de minério a 0,443 % de cobre e 0,407 gramas por tonelada (g/t) de ouro calculados com teor de corte a 0,30 % de cobre.

Em 1979 a Eluma adquiriu da Inco o restante dos interesses na Mineração Serras do Leste assumindo o controle integral do projeto.

Entre 1979 e 1981, com o apoio técnico da Noranda Mines do Canadá, uma das principais mineradoras mundiais de cobre, e da Parsons, companhia de engenharia norte americana especializada em projetos de mineração e metalurgia de cobre, deu-se seqüência aos trabalhos de pesquisa. Nesse período foram perfurados mais 81 furos diamantados (série “M”), com diâmetros BX e NX, num total de 10.500 m, reduzindo-se para 100 m x 50 m o espaçamento entre furos na parte central do depósito. Todas as amostras desta campanha foram analisadas para ouro e cobre. Seguiu-se um programa adicional de furos rasos (201 furos) com diâmetro HX denominados série “S”, perfazendo 2.800 m de sondagem com a finalidade específica de avaliar o horizonte saprolítico.

Dando seqüência aos estudos, foram abertos um poço de 92 m de profundidade e duas galerias transversais com 55 m cada, gerando minério em quantidade suficiente para a realização de testes metalúrgicos de bancada e em planta piloto. Estes ensaios foram realizados no laboratório da Metais de Goiás S/A (METAGO), sob a supervisão direta dos técnicos da Noranda. Concomitantemente, foram efetuados os estudos de avaliação de reservas, de hidrologia, barragens, estabilidade de taludes, mineralogia e outros que se fizeram necessários ao apoio do projeto. Estes trabalhos culminaram com o desenvolvimento de um Plano de Lavra detalhado e projetos de produção de concentrado de cobre e ouro.

As análises químicas dos testemunhos de sondagens executadas até 1989 foram realizadas no laboratório do IPT em São Paulo, e parte delas reanalisadas pelo Skyline Labs em Tucson, Arizona (E.U.A.).

Os estudos de viabilidade econômica realizados no início da década de 80 concluíram pela inviabilidade do empreendimento devido à realidade da época principalmente em relação ao tamanho conhecido do depósito, ao baixo preço do cobre e a escassez e alto custo de energia elétrica na região.

A tabela 4.1 sumariza a quantificação dos trabalhos de exploração mineral desenvolvidos no período entre 1974 a 1989.

**Tabela 4.1 - Trabalhos de exploração mineral executados entre 1974 e 1989.**

FASE EMPRESA ANO	DISCRIMINAÇÃO	QUANTIDADES			ELEMENTOS ANALISADOS
		FUROS	AMOSTRAS	OUTROS	
PROSPECÇÃO GERAL MINERAÇÃO SERRAS DO LESTE 1974 - 1975	-Sedimento de corrente -Aeroeletromagnetometria -Polarização induzida		739	200 km	Cu, Pb, Zn, Fe, Ni
MINERAÇÃO SERRAS DO LESTE , ELUMA PROSPECÇÃO DE SEMIDETALHE E DETALHE 1976- 1979	-Planialtimetria -Amostragem de Solo -Magnetometria -Polarização Induzida -Mapeamento Geológico -Sondagem Exploratória -Sond. Sistemática 1 -Sondagem Exploratória 2 -Secções Delgadas -Secções Polidas -Análises Rocha Total	45 35 49	16.516 2.304 3.148 3.031 30 116	16 km 246,5 km 127,9 km 43,5 km 15,0 km 2.770 m 5.697 m 5.797m	Cu, Pb, Zn, Fe, Ni Cu, Pb, Zn, Cu, Au Cu, Pb, Zn, Au, Ag Cu, Pb, Zn, Au, Ag Vários
FASE DE DETALHAMENTO ELUMA, NORANDA E PARSONS 1980 - 1981	-Sondagem de Detalhamento --- Sondagem de Solo -Reconhecimento Fotográfico -Restituição Aerofotográfico 1:2.000 -Restituição Aerofotográfica: 1:5.000 -Poço de Pesquisa -Galerias	85 201	6.484 2.840	10.429 m 2.836 m 192 km <sup>2</sup> 30 km <sup>2</sup> 90 km <sup>2</sup> 92 m 110 m	Cu, Au, Ag e S Au, Cu e Ag Cu, Au, e S Cu, Au, e S
FASE COMPLEMENTAR ELUMA 1989	Sondagem Complementar	7	463	654m	Cu e Au

Em 1995 a Mineração Santa Elina S.A. adquiriu os direitos minerários através de sua coligada Mineração Maracá S.A., e executou uma campanha de sondagens, visando uma melhor definição da mineralização aurífera no horizonte saprolitizado. Foram efetuados 415 furos diamantados rasos, diâmetro HX, em uma malha de 100 m x 50 m totalizando 8.320 metros perfurados (série “CHD”).

Em 1996 a Mineração Santa Elina S.A. amostrou e analisou para ouro, os testemunhos de sondagem dos primeiros 78 furos executados pela Inco em 1979, já que esta empresa, à época, havia analisado apenas parte dos testemunhos destes furos.

Foi então conduzido pela empresa Echo Bay Mines (E.U.A.), um novo estudo de pré-viabilidade econômica apontando uma reserva de 153 milhões de toneladas a 0,399 % de cobre e 0,369 gramas por tonelada de ouro e uma expectativa de, após uma nova e intensa campanha de sondagem, expandi-la a 237 milhões de toneladas de minério.

Em abril de 1996, a Echo Bay Mines adquiriu 44 % dos interesses da Mineração Santa Elina e assumiu a direção técnica do projeto. Foi então elaborado um novo plano de trabalho, tendo como objetivo verificar os dados preexistentes, ampliação das reservas conhecidas e obtenção de novos parâmetros, para que se pudesse atualizar o estudo econômico do empreendimento.

O programa de trabalho executado incluiu estudos geológicos com sondagens, descrição de testemunhos (geotécnica e geológica), amostragens e análises químicas, estudos petrográficos de seções delgadas (53) e polidas (12), estudos geotécnicos e de meio ambiente, ensaios de beneficiamento, e estudos de viabilidade econômica. Este programa foi periodicamente avaliado e certificado por auditorias técnicas internas e externas.

Na última campanha de sondagem, executada em 1996, foram perfurados 39.596 metros na área do depósito, sendo 38.539 metros de furos diamantados, diâmetro BX/NX, e 1.057 metros de circulação reversa. Nos alvos em torno do depósito, foram efetuados 3.497 metros de furos diamantados com diâmetros BX/NX. A tabela 4.2 relaciona todos os programas de sondagem implantados no depósito de Chapada, inclusive aqueles já listados na tabela 4.1, resultando em um total de 78.428 metros perfurados em 1.153 furos.

Em 1997 foram contratadas as empresas de engenharia Kilborn-SNC Lavalin (Colorado,EUA) e Independent Mining Consultants (Arizona,EUA) para a execução do estudo de viabilidade econômica final, incorporando os estudos realizados nos anos anteriores. Este estudo foi concluído positivamente em janeiro de 1998 ressaltando as seguintes virtudes do empreendimento: depósito de classe mundial; baixo custo de preparação do terreno devido

a topografia plana; baixo custo de lavra a céu aberto devido a baixa relação estéril/minério e dureza da rocha; concentrado de cobre de alta qualidade totalmente livre de impurezas deletérias; infraestrutura (estradas, energia elétrica, água, cidades) e mão-de-obra treinada disponíveis na região; propriedade minerária e fundiária consolidadas. O elevado investimento requerido para a implantação do projeto (147 milhões de dólares americanos) levou a Mineração Maracá a elaborar um plano de financiamento integrando fornecedores de equipamentos, empreiteiras de lavra, instituições financeiras nacionais e internacionais. Este plano tem sido implementado nos últimos anos com alguns reveses em função da conjuntura internacional e atualmente está na fase final com a realização de estudos complementares para atendimento das garantias de desempenho. Em função do cronograma de estudos e financiamento o início de implantação do projeto está previsto para 2005, devendo entrar em operação dois anos depois.

**Tabela 4.2 – Programas de sondagem executados no projeto Chapada entre 1976 a 1996.**

ANO	EMPRESA	SÉRIE	TIPO	NÚMERO	Nº DE FUROS	METROS	OBJETIVOS
1976	Inco	M	BX	M1 a M6	6	918,83	Testar anomalia
1976	Inco	F	AX	F1 a F46	48	2.769,53	Malha 200 m
1976-79	Inco/Eluma	M	BX/NX	M6 a M84	78	10.500,00	Centro - 100 m
1979-81	Eluma	M	BX/NX	M85 a M169	81	10.429,06	100 m x 50 m no centro do corpo mineralizado
1979- 1981	Eluma	S	HX	S1 a S201	201	2.800,00	Anomalias de Au em solos
1989	Eluma	M	BX/NX	M170 a M176	7	653,92	Extensão nordeste do corpo de minério
1995	Santa Elina	CHD	HX		416	8.320,00	Au em saprolito
1996	Santa Elina	M	BX/NX	M177 a M440	263	38.539,76	Avaliação da reserva / incremento de recursos
1996	Santa Elina	RC		RC1 a RC18	18	1.057,00	Condenação para área industrial
		JVE	BX/NX		36	3.497,08	Prospecção regional
<b>Total</b>					<b>1.153</b>	<b>78.428,18</b>	

## 4.2 Método de coleta e integração dos dados

O conjunto de dados utilizados no presente trabalho pertence a Mineração Maracá S.A., subsidiária da Mineração Santa Elina S.A., que implantou a partir de 1996 a seguinte sistemática de trabalho para a obtenção e integração dos mesmos:

1. Redescrição dos testemunhos de todos os furos de sonda anteriormente executados (1976 a 1989), visando um padrão único de informações, sendo criadas planilhas específicas para que estas informações pudessem ser armazenadas e tratadas no Centro de Processamento de Dados (CPD);
2. Levantamento topográfico dos furos de sonda adotando o sistema de coordenadas UTM e cotas verdadeiras;
3. Descrição geotécnica dos novos testemunhos de sondagem. Após a descrição geotécnica, os testemunhos de sondagem foram serrados e, então, efetuada a descrição geológica e o plano de amostragem.
4. As amostras foram preparadas no laboratório Geolab, instalado nas dependências da empresa, na cidade de Alto Horizonte. A preparação consistiu em britar a metade do testemunho de sondagem em granulometria abaixo de 6,3mm em britador de mandíbulas, seguida da moagem até 1mm em britador de rolos. A amostra foi então homogeneizada e dividida em 3 partes iguais, sendo um terço pulverizado a menos 150 malhas e dois terços arquivados. O terço pulverizado, após homogeneização, foi dividido em duas frações de 500 g: uma destinada a análise química e outra arquivada como polpa (ver fluxograma de preparação de amostras na figura 4.1);
5. Após preparadas, as amostras foram enviadas ao laboratório Geolab em Belo Horizonte, Minas Gerais, para análise de cobre via extração multiácida e absorção atômica. As análises de ouro foram realizadas via *fire-assay* pelo laboratório Nomos, Rio de Janeiro. O programa de controle de qualidade de análises químicas baseou-se na inserção sistemática de diferentes tipos de amostras com resultados analíticos conhecidos, às amostras dos testemunhos de sondagem a serem analisadas, consistindo de:
  - Amostras denominadas Padrões (três diferentes padrões de teores conhecidos);
  - Amostras denominadas Branco (valor zero);

- Duplicatas de amostras do testemunho a ser analisado, além de uma verificação sistemática em laboratórios tradicionais do Brasil e no exterior;

A figura 4.2 ilustra graficamente o fluxo de amostragem e o programa de controle de qualidade analítica dos testemunhos de sondagem;

6. Estudos micro-petrográficos; seções delgadas e polidas;
7. Elaboração de seções geológicas e de teores de cobre e ouro obtidos nas sondagens;
8. Plotagem das seções e modelagem geológica do corpo de minério;
9. Análise estatística e variográfica, seguida da estimação de teores por krigagem ordinária em modelo de blocos e cálculo de reservas utilizando os *software* Gslib e Vulcan 3.0.

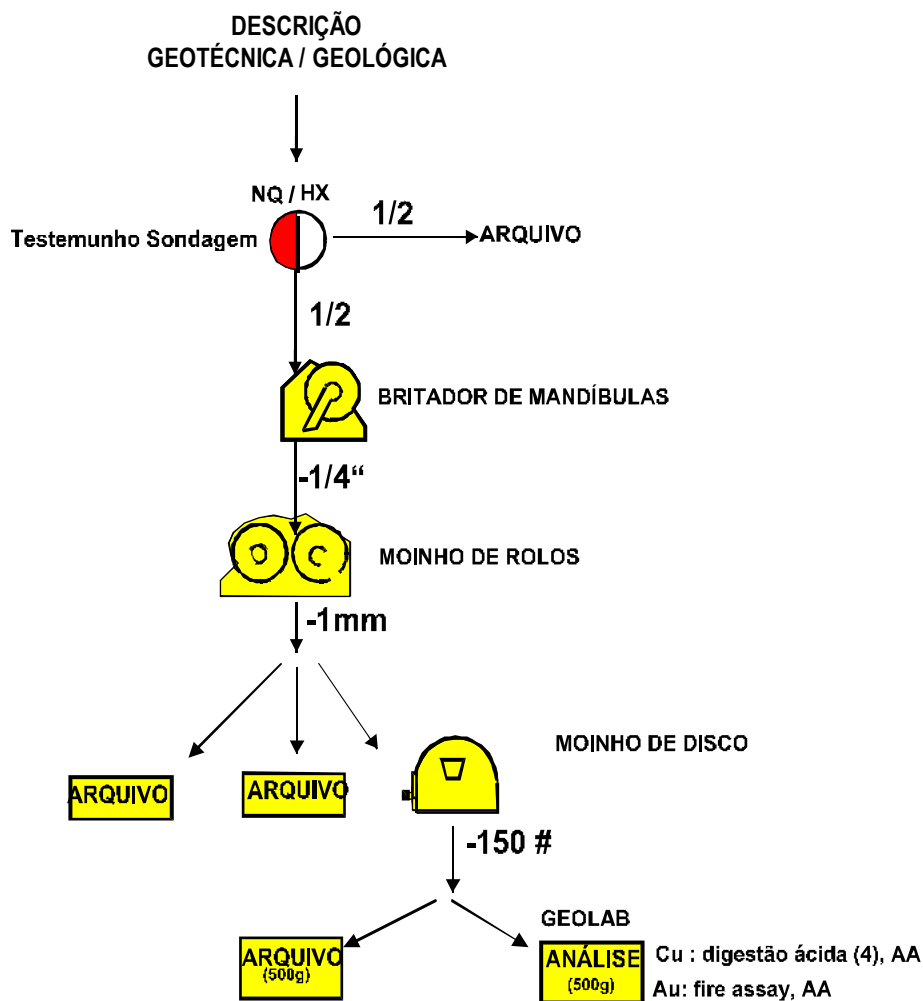


Figura 4.1 - Fluxograma de preparação de amostras de testemunhos de sondagem.

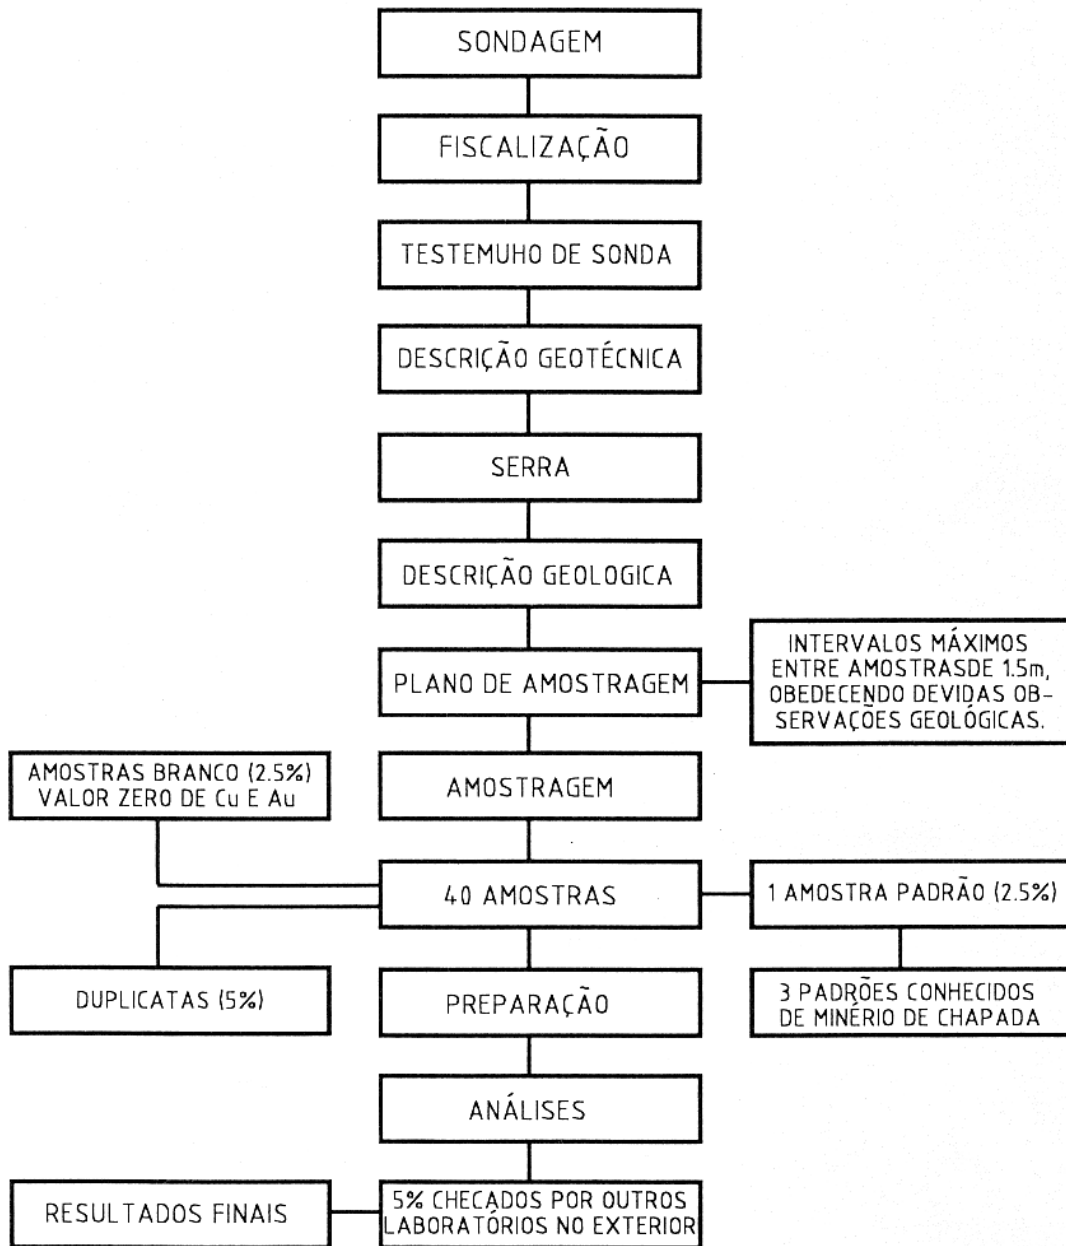


Figura 4.2: Fluxograma de amostragem e controle de qualidade analítica das amostras de sondagem.

### 4.3 Base de dados de sondagem

Para homogeneização dos resultados obtidos e armazenagem no banco de dados do CPD, fez-se necessária a criação de planilhas e códigos específicos para descrição geotécnica e geológica.

A localização espacial dos furos de sonda e das respectivas amostragens foi obtida com levantamento topográfico e aferição de rumo e mergulho dos furos a cada 50 metros de profundidade, gerando os registros para as variáveis espaciais “X”, “Y” e “Z” em dois sistemas de coordenadas: UTM e local arbitrário. Os desvios de mergulho e rumo de sondagem não foram significativos, uma vez que, a maioria dos furos foi perfurada na vertical, e apenas 11% dos furos foram inclinados e pouco profundos.

#### 4.3.1 Dados Geotécnicos

Geólogos treinados descreveram para a geotecnia cerca de 34.000 m de testemunhos, correspondentes aos furos de sonda M-182 a M-440, onde foram medidas as recuperações de testemunhos e analisados o grau de intemperismo, resistência, foliação e sistemas de fraturas.

As planilhas de dados geotécnicos elaboradas no aplicativo Excel 97 contêm as seguintes informações:

- Intervalo de manobra da sonda;
- Recuperação do testemunho de sondagem em cada intervalo;
- RQD – índice de designação de qualidade de rocha expresso em porcentagem, obtido a partir da razão entre o comprimento medido dos pedaços de testemunho com tamanho igual ou superior a 10 cm, medida esta equivalente a duas vezes o diâmetro do testemunho, e o comprimento do intervalo testemunhado. Afere a qualidade da rocha *in situ*;
- Fraturas - frequência de fraturas, que é o número de fraturas naturais dividido pelo comprimento do intervalo testemunhal (descontadas as zonas fragmentadas). Para tanto são descritos:
  - maior pedaço de testemunho intacto entre fraturas,
  - tamanho de zonas fragmentadas (*rubble zones*),
  - tipos de preenchimento de fraturas;

A frequência de fraturas é utilizada para determinar o espaçamento entre fraturas dentro de um maciço rochoso, tendo uma influencia direta sobre sua resistência e comportamento.

- Índice de Resistência – mede qualitativamente a resistência da rocha à compressão simples. È descrita por um geólogo capacitado para a tarefa usando um canivete de mão e martelo para rocha. Adotou-se o seguinte código de resistência da rocha:
  - 0 - extremamente fraco/débil (riscável com a unha).
  - 1 - muito fraco/débil (esfarela com a ponta do martelo)
  - 2 - fraco/débil (pode ser descascada com o canivete com dificuldade)
  - 3 - médio (pode ser fraturada com um único golpe de martelo)
  - 4 - forte/resistente (requer mais de um golpe de martelo para fraturar).
  - 5 - muito forte/resistente (requer muitos golpes de martelo para fraturar)
  - 6 - extremamente forte/resistente (pode ser apenas lascada com o martelo)
- Intemperismo – o grau de intemperismo da rocha avaliado visualmente foi expresso através dos seguintes códigos:
  - 1 - sem intemperismo
  - 2 - < 5% rocha intemperizada
  - 3 - < 50% rocha intemperizada
  - 4 - > 50% rocha intemperizada
  - 5 - 100% rocha está decomposta
  - 6 – solo

O grau de intemperismo geralmente aumenta com a profundidade e influencia a resistência da rocha.

#### **4.3.2 Dados geológicos**

Foram redescritos os testemunhos de sonda já existentes e efetuada a descrição de 51.413 metros de novos testemunhos. Este estudo constou de: descrição macroscópica (uso de lupas de bolso) com classificação do tipo litológico, identificação e grau do tipo de alteração hidrotermal, níveis de alteração intempérica, tipos e percentuais de sulfetos presentes, plano de amostragem e amostragem para análises químicas, propriamente ditas.

A descrição geológica dos testemunhos foi transferida para o banco de dados com a seguinte estrutura:

- Tipo litológico – descrição do tipo de rocha predominante no intervalo amostral do testemunho de sondagem (1,40 metros em média) com os seguintes códigos:

- 1 Solo
- 2 Solo variegado
- 3 Saprolito Oxidado
- 4 Saprolito Sulfetado
- 5 Rocha intemperizada
- 10 Biotita xisto
- 20 Antofilita xisto
- 30 Anfíbolio xisto
- 40 Biotita Cianita xisto
- 50 Anfíbolio Cianita xisto
- 60 Anfíbolito
- 70 Biotita Quartzo xisto
- 80 Pegmatito
- 90 Veios de Quartzo > 1 metro
- 100 Metatufo
- 110 Sericita Quartzo xisto
- 200 Anfíbolito Bandado
- 300 Micro-granodiorito

- Minerais acessórios - segundo dígito no código litológico:

- 1 Granada
- 2 Silimanita
- 3 Estauroлита
- 4 Cianita
- 5 Epidoto
- 6 Muscovita
- 7 Granada e estauroлита
- 8 Estauroлита e cianita

- Oxidação – identifica os tipos de minério segundo a classificação metalúrgica, expressa através dos seguintes códigos:
  - 1 Solo e laterita
  - 2 Zona de solo argiloso
  - 3 Saprolito Oxidado
  - 4 Saprolito Sulfetado
  - 5 Rocha Intemperizada
  - 6 Rocha Fresca
  
- Alteração hidrotermal – registra a presença das seguintes alterações hidrotermais:
  - cloritização
  - sericitização
  - silicificação
  - epidotização
  - carbonatização
  - piritização;e mede a intensidade das alterações segundo o código:
  - 0 Ausente
  - 1 Fraca
  - 2 Media
  - 3 Forte
  
- Minerais sulfetados – identifica o mineral metálico predominante segundo o código:
  - 1 Pirita
  - 2 Calcopirita
  - 3 Bornita
  - 4 Pirrotita
  - 5 Esfalerita
  - 6 Galena
  - 7 Magnetita

- Porcentagem de Sulfetos – estimação visual da quantidade de sulfetos no intervalo amostral segundo o código:

0	Ausente
0.1	Traço
0.5	<1%
1	1%
1.5	1-2%
2	2%
2.5	2-3%
3	3%
4	3-5%
5	5%
6	5-7%
7	7%
8	>8%

- Razão Calcopirita / Pirita – estimação visual da quantidade relativa de cristais de calcopirita (cpy) e pirita(py) segundo o código:

0	Ausência de calcopirita
0.25	1 calcopirita para 4 piritas (1cpy / 4 py)
0.75	1 cpy / 2 py
0.75	3 cpy / 4 py
1	1 cpy / 1 py
1.25	5 cpy / 4 py
1.5	3 cpy / 2 py
2	2 cpy / 1 py
3	3 cpy / 1 py

#### 4.3.3 Dados de análises químicas

Foram analisadas cerca de 47.500 amostras para ouro (*fire assay*) e 33.000 para cobre (absorção atômica). Os resultados analíticos foram incorporados ao banco de dados geológicos compondo as colunas “Cupct”, teor de cobre expresso em porcentagem, e “Auppm”, teor de ouro em partes por milhão.

## CAPÍTULO 5. APLICAÇÃO DAS REDES NEURAIS

---

### 5.1 Introdução

O problema a ser modelado é a previsão de teores de cobre e ouro a partir de atributos geológicos e geotécnicos no depósito de Chapada. Trata-se de construir um sistema dinâmico de funções numéricas não-lineares a partir de múltiplas variáveis com comportamentos distintos e mal conhecidos. As premissas sobre a forma e distribuição das variáveis dependentes e independentes são mínimas. O sistema precisa ser flexível, estável e robusto pois os dados serão atualizados freqüentemente e cheios de ruídos. Deseja-se ainda um sistema veloz com demanda computacional aceitável e cuja complexidade seja assimilável por profissionais não especializados. A técnica proposta para a construção deste sistema são as redes neurais artificiais alimentadas adiante (“feedforward”).

A estratégia de pesquisa adotou os seguintes passos:

1. Aplicar a técnica em uma área piloto do depósito de Chapada;
2. Selecionar a arquitetura de rede com melhor desempenho na área piloto;
3. Comprovada a viabilidade da técnica, otimizá-la e aplicá-la ao restante do depósito.

### 5.2 Conjunto de dados utilizados

Os dados selecionados para a aplicação do método proposto foram extraídos das bases de dados geológicos e geotécnicos do Projeto Chapada. Como descrito anteriormente no Capítulo 4 os dados foram obtidos através da descrição geológica e geotécnica e da análise química dos testemunhos de sondagens rotativas diamantadas.

O banco de dados original foi elaborado no aplicativo Microsoft-Excel 5.0/95, distribuído em planilhas individualizadas para os diferentes tipos de informação a saber: coordenadas espaciais dos furos de sonda, azimuth-mergulho-desvio de cada furo, variáveis geológicas e análises químicas, ensaios de peso específico, variáveis geotécnicas, e controle de qualidade de análises químicas.

Os dados geológicos e geotécnicos, de interesse específico deste estudo, constituem em sua versão integral matrizes com tamanho 47.943 x 21 (registros linhas x variáveis colunas) e 15.045 x 16, respectivamente. Isto significa dizer que o banco de dados geológicos contém 47.943

amostras com informações sobre tipo de rocha, tipo e intensidade de alteração hidrotermal e sulfetos, grau de oxidação, e teores de cobre e ouro.

Essas amostras são provenientes de testemunhos de 440 furos de sonda verticais (95% dos casos) e inclinados distribuídos em malha regular de 100 m x 50 m com profundidades média e máxima iguais a 180 m e 400 m, respectivamente. O banco de dados geotécnicos é menor e provém de 58% dos furos com registros geológicos, isto é, do conjunto de 440 furos apenas 259 receberam descrição geotécnica.

Para a aplicação da técnica de redes neurais foi adotado o banco de dados formado pelo conjunto composto por 237 furos de sonda (série “M-177” a “M-413”) com descrição geológica e geotécnica localizados na área da futura lavra. A redução do conjunto de dados foi motivada também pelo fato dessa série de furos ter sido executada em uma mesma campanha e descrita segundo o mesmo padrão, o que é particularmente importante no tratamento de variáveis qualitativas. Esta redução não compromete a representatividade dos dados uma vez que provêm de 21.212 amostras obtidas em sondagens distribuídas ao longo de todo o depósito (figura 5.1).

Devido à elevada memória computacional demandada pelos algoritmos empregados no treinamento das redes neurais optou-se pela segmentação do banco de dados em quatro subconjuntos. Estes subconjuntos correspondem a blocos contíguos numerados de “1” a “4” no sentido sudoeste-nordeste do depósito (figura 5.1). A tabela 5.1 apresenta o número de amostras contidos em cada bloco.

Tabela 5.1 – Subconjuntos de dados por blocos.

Bloco	Localização (X)	Número de amostras
1	450 a 1550	6252
2	1550 a 2750	7375
3	2750 a 4050	2473
4	2450 a 4050	5112

O bloco “1” foi selecionado como piloto para a comprovação da aplicabilidade da técnica de redes neurais na área de estudo por ser representativo da geologia da jazida, principalmente do espectro litológico, e da mineralização de cobre e ouro.

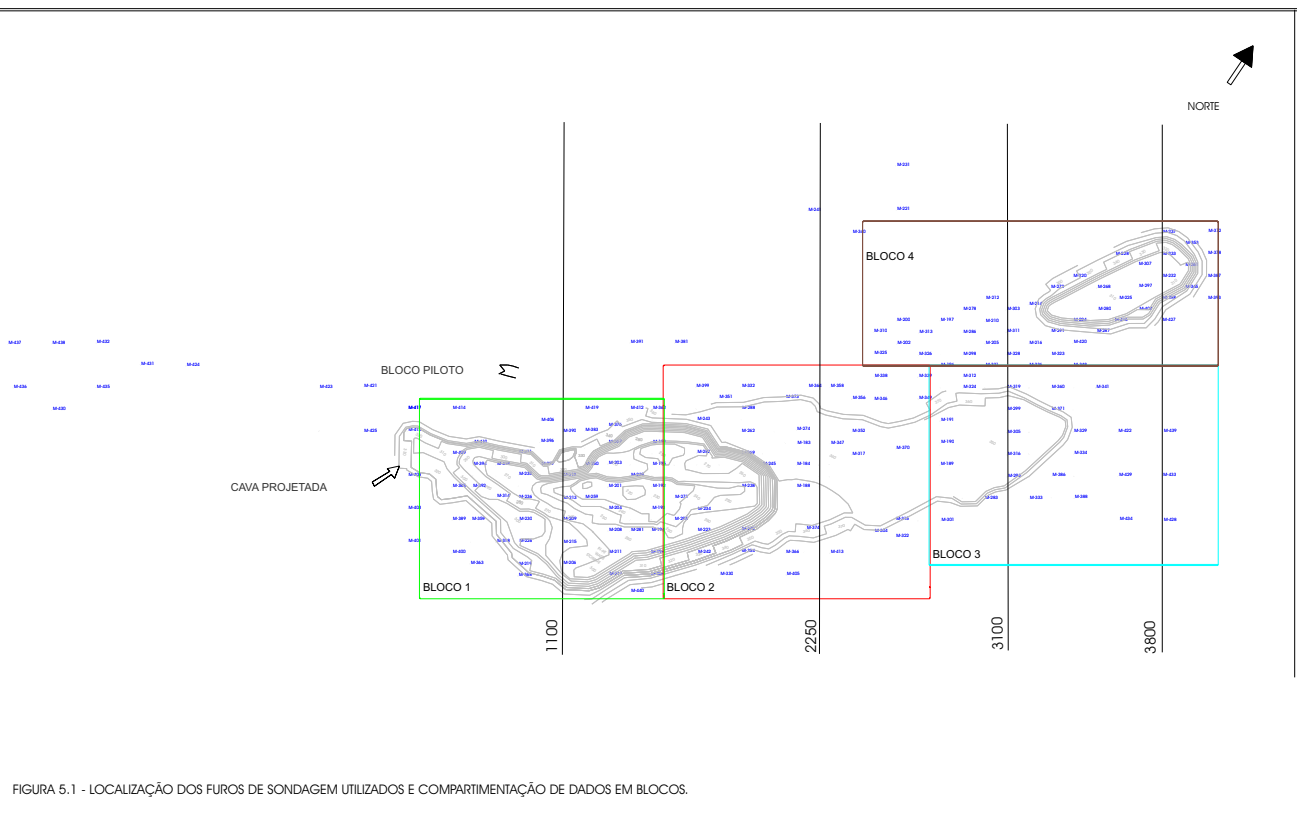


FIGURA 5.1 - LOCALIZAÇÃO DOS FUIROS DE SONDAAGEM UTILIZADOS E COMPARTIMENTAÇÃO DE DADOS EM BLOCOS.

### 5.2.1 Banco de dados piloto

O bloco “1” ocupa na superfície uma área de 975 m x 850 m na parte sul do depósito incluindo 10.023 m de sondagem ao longo de 79 furos distribuídos em dez seções espaçadas em 100 m com furos distanciados em 50 m formando uma malha regular.

Foram descritos e amostrados para análise química 7.162 intervalos com comprimento médio igual a 1,40 m compondo o banco de dados geológicos. O banco de dados geotécnicos apresenta 4.051 registros com comprimento médio igual a 2,27 m totalizando 9.183 metros de testemunhos de sondagem descritos. Esta diferença de totalização de metragem entre os dois bancos refere-se aos intervalos iniciais de cada furo constituídos por solo ou saprolito onde obviamente não é possível descrever algumas variáveis geotécnicas tais como frequência de fraturas e RQD. Fez-se necessária a fusão dos bancos de dados geológicos e geotécnicos, uma vez que os intervalos amostrais dos mesmos não são coincidentes. Para tanto, os furos com registros em ambos os bancos foram exportados para o aplicativo Microsoft Access 2000 e manipulados de forma a compor um banco único com variáveis geológicas e geotécnicas indexados pelos intervalos amostrais geológicos. A fusão dos bancos resultou, após a exclusão das variáveis redundantes, em uma matriz de 6.252 linhas por 13 colunas conforme mostrado no diagrama da figura 5.2. A tabela 5.2 apresenta o nome e descrição das variáveis do banco piloto.

Tabela 5.2 – Variáveis do banco de dados piloto.

CATEGORIA	VARIÁVEL	DESCRIÇÃO
GEOLÓGICAS	AUPPM	Teor de ouro (ppm)
	CUPCT	Teor de cobre (%)
	LITHO	Tipo litológico
	CHLORI	Alteração hidrotermal - Cloritização
	SERICI	Alteração hidrotermal - Sericitização
	SILICI	Alteração hidrotermal - Silicificação
	EPIDOT	Alteração hidrotermal - Epidotização
	CARBON	Alteração hidrotermal - Carbonatização
	PYRIT	Alteração hidrotermal - Piritização
	CP_PY	Razão calcopirita / pirita
	SULPCT	Porcentagem de sulfetos
GEOTÉCNICAS	FRACT	Frequencia de fraturas
	RQD	Medida da qualidade da rocha

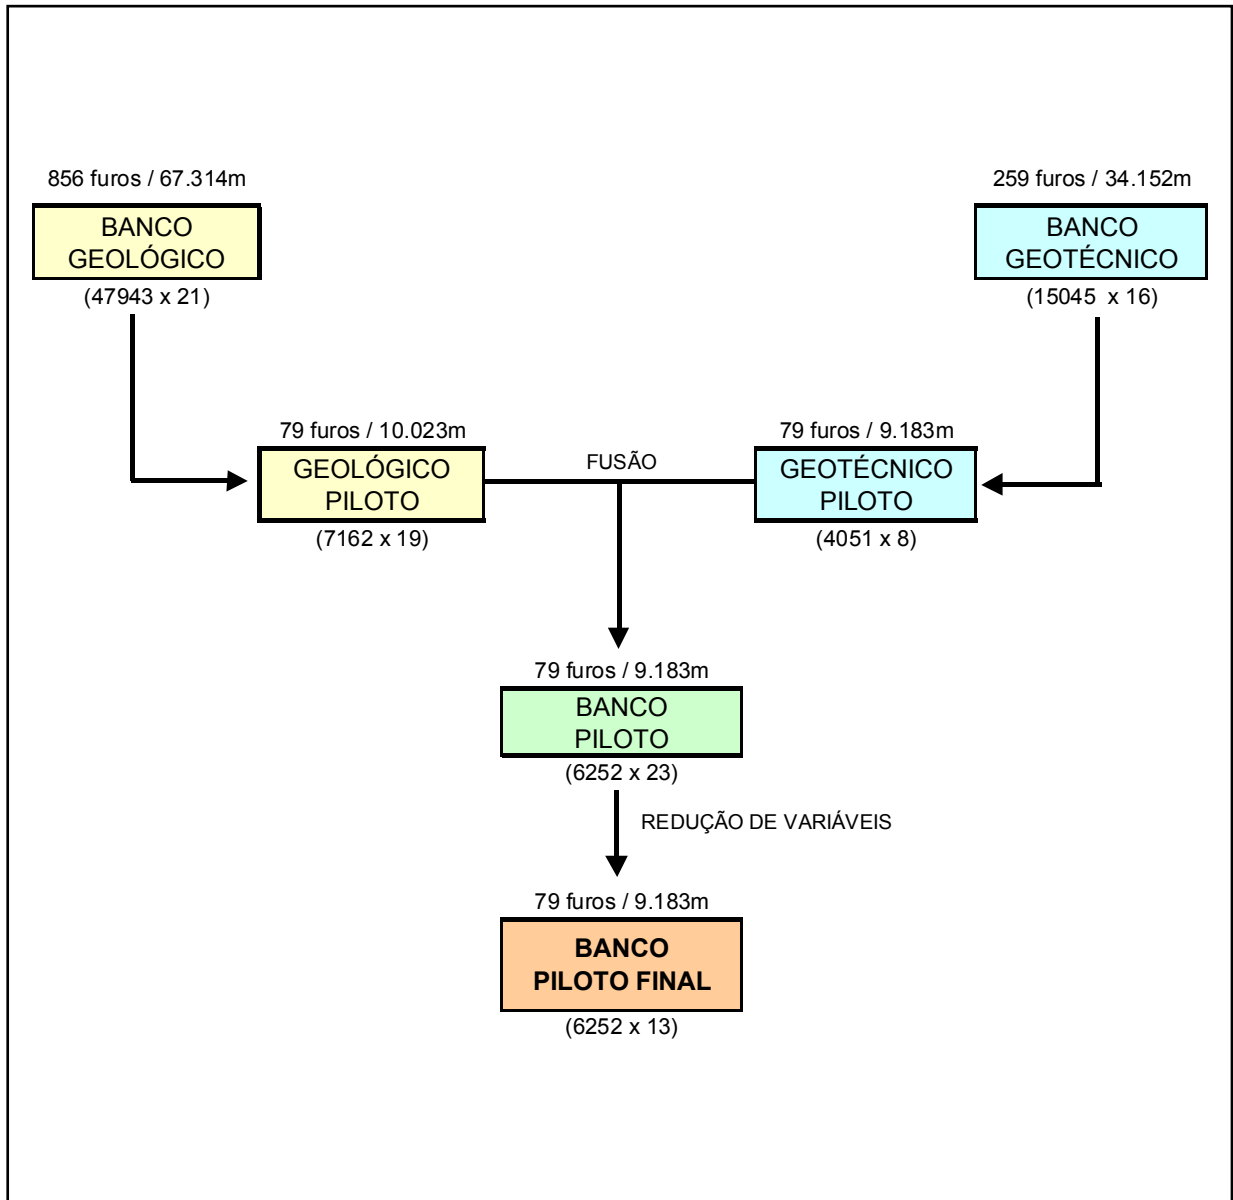


Figura 5.2 – Fluxograma de preparação do banco de dados piloto.

### 5.3 Análise estatística das variáveis

A análise estatística objetiva a caracterização da distribuição individual das variáveis e suas correlações como instrumento de conhecimento do problema a ser modelado pelas redes neurais. Embora o projeto de uma rede neural não requeira premissas sobre a distribuição das variáveis, informações prévias e invariâncias devem ser incorporadas simplificando com isso o projeto por não ter que aprendê-las. Uma situação muito comum é o descarte, durante a preparação de dados, de variáveis ditas “redundantes” por apresentarem variância muito baixa.

Segundo o critério de classificação baseada na natureza dos valores que podem assumir, sejam numéricos ou não numéricos, as variáveis geológicas e geotécnicas do banco de dados de sondagem de Chapada podem ser agrupadas em 4 tipos:

- Qualitativas nominais: litologia (“LITHO”);
- Qualitativas ordinais: alterações hidrotermais: cloritização (“CHLORI”), sericitização (“SERICI”), silicificação (“SILIC”), epidotização (“EPIDOT”), carbonatização (“CARBON”) e piritização (“PYRIT”);
- Quantitativas discretas: minerais de minério: razão calcopirita / pirita (“CP\_PY”) e porcentagem de sulfetos (“SULPCT”) e variáveis geotécnicas: frequência de fraturas (“FRACT”) e qualidade da rocha (“RQD”);
- Quantitativas contínuas: concentração metálica: representa a quantificação da mineralização através dos teores de cobre (“CUPCT”) e ouro (“AUPPM”), constituindo as variáveis “alvo” da presente aplicação da técnica de redes neurais.

O conjunto de dados a ser analisado foi tomado do banco de dados piloto, considerado representativo das características geológicas e geotécnicas predominantes no depósito de Chapada.

A fim de evitar distorções na análise, os registros com valores negativos em uma ou mais variáveis foram excluídos reduzindo assim o conjunto de dados de 6487 para 6252, equivalente a um corte de 3,6% (235 amostras). Os valores negativos significam que o atributo não foi descrito ou analisado, ou seja, não há estimativa da variável.

Os parâmetros estatísticos descritivos de todas as variáveis, com exceção da variável “LITHO” (litologia), são apresentados na tabela 5.3.

Tabela 5.3 – Estatística descritiva do conjunto de dados piloto.

Variável	Média	Desv. Padrão	Coef. de Variação	Mediana	Mínimo	Máximo	Quartil Inferior	Quartil Superior	Variância	Assimetria	Kurtose
<b>CHLORI</b>	0.98	1.14	1.16	0	0	3	0	2	1.294	0.607	-1.192
<b>SERICI</b>	1.13	1.07	0.95	1	0	3	0	2	1.146	0.353	-1.226
<b>SILICI</b>	0.80	0.97	1.20	0	0	3	0	2	0.933	0.855	-0.500
<b>EPIDOT</b>	0.25	0.76	3.09	0	0	3	0	0	0.582	2.968	7.260
<b>CARBON</b>	1.27	1.26	0.99	1	0	3	0	3	1.588	0.232	-1.628
<b>PYRIT</b>	0.33	0.82	2.52	0	0	3	0	0	0.676	2.411	4.387
<b>CP_PY</b>	0.32	0.42	1.31	0	0	3	0	0.5	0.177	1.330	2.259
<b>SULPCT</b>	1.67	1.08	0.65	1.5	0	8	1	2	1.171	1.299	2.628
<b>FRACT</b>	0.56	0.61	1.09	0.34	0	6.04	0	0.86	0.374	1.880	6.386
<b>RQD</b>	93.98	12.39	0.13	99.06	0	100	94.07	100	153.490	-3.634	16.553
<b>AUPPM</b>	0.15	0.42	2.75	0.05	0.002	24.02	0.002	0.16	0.175	31.235	1701.563
<b>CUPCT</b>	0.19	0.27	1.39	0.1	0.005	6	0.03	0.26	0.070	6.084	92.841

N=6252

As litologias foram classificadas segundo o código numérico arbitrário descrito no capítulo 4 e registradas sob a variável “LITHO”. Tratando-se de uma variável não numérica deve-se tomar certos cuidados na preparação de dados para a análise estatística. O primeiro passo da preparação consistiu em reduzir os tipos de rocha de 18 para 14 mediante agrupamento de litologias com composição mineralógica principal similar. A tabela 5.4 mostra os códigos originais e os agrupados.

Os principais tipos de rocha da área piloto, a exemplo do depósito inteiro, são biotita xistos (57,4%) e anfibólio xistos (27%). Se incluirmos o tipo biotita cianita xistos (8,9%) no grupo de biotita xistos este representará aproximadamente 66% do conjunto de dados. A figura 5.3 apresenta o gráfico de distribuição de frequência da variável “LITHO”. Entre as 6252 amostras observa-se a ausência de dois tipos litológicos: veios de quartzo com espessura maior que 1 metro (código “90”) e sericita quartzo xisto (“110”). Veios de quartzo espessos são raros, mesmo no banco de dados integral do depósito onde representam menos que 0,05% dos registros litológicos. Os sericita quartzo xistos são hidrotermalitos cuja ocorrência é restrita a capa (leste) do corpo mineralizado, em uma área com baixa densidade de furos de sondagem.

Tabela 5.4 - Código de agrupamento de tipos litológicos (“LITHO”)

Original	Agrupado	Descrição
<10	0	Solo, saprolito, rocha intemperizada
>=10 e <20	10	Biotita xisto
>=20 e <30	20	Antofilita xisto
>=30 e <40	25	Anfibólio xisto
>=40 e <50	15	Biotita cianita xisto
>=50 e <60	25	Anfibólio cianita xisto
>=60 e <70	30	Anfibolito
>=70 e <80	18	Biotita quartzo xisto
>=80 e <90	80	Pegmatito
>=90 e <100	90	Veios de quartzo
>=100 e <110	100	Metatufo
>=110 e <200	110	Sericita quartzo xisto
>=200 e <300	35	Anfibolito bandado
>=300	300	Micro granodiorito

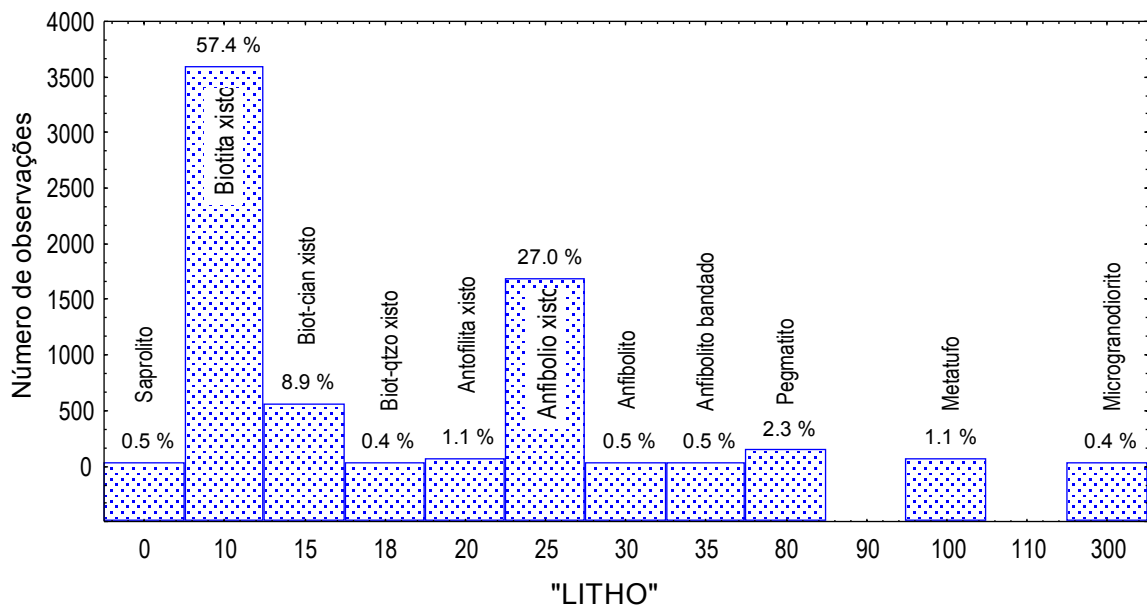


Figura 5.3 – Gráfico de frequência de litologias do conjunto de dados piloto.

O grupo de variáveis qualitativas ordinais composto pela medição de intensidade dos diversos tipos de alterações hidrotermais utiliza uma escala de medição variando de “0” (alteração inexistente) a “3” (forte), com passo igual a 1. O comparativo de distribuição de freqüência dessas variáveis, graficamente representado na figura 5.4, mostra que as alterações hidrotermais mais freqüentes são: sericitização, carbonatização, cloritização e silicificação. A alteração mais intensa é a carbonatização e as menos freqüentes são a epidotização e piritização.

Os histogramas de freqüência individuais (Figura 5.5) evidenciam a distribuição lognormal de todas as variáveis com pico nos valores “0”, ou seja, a predominância da inexistência de alteração, embora apenas 9,4% (586 amostras) dos registros indiquem a ausência total de qualquer tipo de alteração hidrotermal. Caso os valores “0” fossem excluídos, isto é, se analisássemos somente os registros positivos de intensidade da alteração hidrotermal, a cloritização (“CHLORI”) e sericitização (“SERICI”) apresentariam distribuição normal, enquanto as demais variáveis permaneceriam lognormais. É importante lembrar entretanto, que a ausência total ou parcial dos tipos de alterações hidrotermais pode significar mineralização inexistente ou fraca.


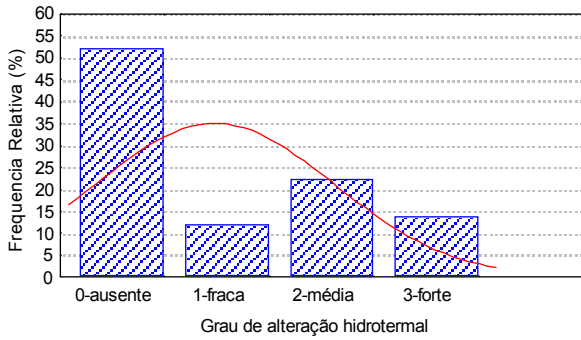



Figura 5.4 – Comparativo de distribuição de freqüência das variáveis de alteração hidrotermal.


### CLORITIZAÇÃO




### SERICITIZAÇÃO




### SILICIFICAÇÃO



### EPIDOTIZAÇÃO



### CARBONATIZAÇÃO



### PIRITIZAÇÃO




Figura 5.5 – Histogramas de frequência das variáveis de alteração hidrotermal.

No grupo de variáveis quantitativas discretas pode-se reconhecer, baseado na natureza das informações, em dois subgrupos: minerais de minério e geotécnicas. As variáveis do sub-grupo minerais de minério referem-se a quantidade de sulfetos na rocha, especificamente aqueles relacionados a mineralização de cobre e ouro. A calcopirita é o principal mineral de minério de cobre assim como a maior parte do ouro de depósito ocorre associado a este mineral. A pirita hospeda parte pouco significativa do ouro contido no depósito, e freqüentemente encontra-se substituída por calcopirita. Minerais de minério secundários são a calcocita e bornita, entretanto não há registros de ocorrência destes minerais no banco de dados.

A variável “CP\_PY” expressa a razão de freqüência de calcopirita em relação a pirita, proporção esta, positivamente relacionada aos teores de cobre e ouro como será demonstrado adiante. A variável “SULPCT” traduz a concentração de sulfetos na rocha, estimada visualmente nos testemunhos de sondagem segundo um padrão pré-estabelecido. A concentração de sulfetos no depósito varia de zero a 8% com média de 1,5% para todas as litologias do banco, elevando-se a 2% no minério. Esta diferença é pouco significativa levando-se em consideração a margem de erro da estimativa visual. Os histogramas de freqüência exibidos na figura 5.6 evidenciam distribuição lognormal para as duas variáveis com cauda alongada à direita, reflexo da predominância dos baixos valores. Os resultados do teste de Kolmogorov-Smirnov (K-S) mostrados na mesma figura, confirmam a não normalidade da distribuição. Entretanto no caso específico da variável “SULPCT” a distribuição aproxima-se mais da normalidade como pode ser observado na curva de frequência do histograma, e corroborado pelo índice “D” do teste K-S e pela proximidade da média com a mediana (tabela 5.3).

As variáveis geotécnicas “FRACT” e “RQD” contêm registros em escalas distintas, expressas respectivamente em unidades e porcentagens. A variável “FRACT” mede a proporção relativa de número de fraturas por intervalo amostral, e parte dessas fraturas pode estar associada a zonas de mineralização mais intensa, hipótese esta a ser testada neste estudo. A variável “RQD” está associada a “FRACT” tendo em vista a constatação genérica de que a qualidade da rocha medida em “RQD” é tanto maior quanto menor o grau de fraturamento do maciço rochoso. Os histogramas de freqüência e o teste K-S apresentados na figura 5.7 rejeitam a hipótese de normalidade para a distribuição das variáveis geotécnicas, sugerindo uma conformação lognormal, fortemente assimétrica. As assimetrias são opostas sendo positiva para “FRACT” e negativa para “RQD”. É interessante notar que “RQD” é a única variável do banco de dados com assimetria negativa, que é reflexo da concentração de valores altos. Adicionalmente apresenta o menor coeficiente de variação (tabela 5.3), o que nos permite concluir que a rocha da área piloto é de

elevada qualidade geomecânica. O reflexo prático dessa qualidade é a estabilidade dos taludes da cava de lavra.




Figura 5.6 – Histogramas de frequência das variáveis minerais de minério e teste de normalidade.




Figura 5.7 – Histogramas de frequência das variáveis geotécnicas e teste de normalidade.

A concentração metálica de interesse econômico no depósito, expresso através das variáveis “CUPCT” (teor de cobre) e “AUPPM” (teor de ouro) é de longe o aspecto mais estudado do depósito principalmente quanto a sua distribuição espacial visando a quantificação de reservas. No próximo tópico deste capítulo será apresentada a análise geoestatística visando a caracterização da distribuição espacial da mineralização.

O teor médio de cobre das amostras piloto expresso em porcentagem é 0,19, com valores variando de 0,005 (limite inferior de detecção analítica do laboratório) a 6 (tabela 5.3). O coeficiente de variação é elevado (139%), porém dentro do padrão de regularidade de depósitos minerais desse tipo. Comparativamente ao depósito como um todo, a área piloto apresenta diferenças discretas: teor médio mais baixo (0,19% *versus* 0,22%) e maior variabilidade (139% *versus* 107%).

O teor médio de ouro das amostras piloto em “ppm” (partes por milhão) ou “g/t” (grama por tonelada métrica) é 0,15, quase idêntico à média do depósito integral (0,16), com valores variando de 0,002 a 24,02. O coeficiente de variação é bastante elevado (275%) e fortemente influenciado por alguns poucos valores extremos. Este coeficiente pode ser significativamente diminuído com a retificação ou exclusão dos valores extremos, como mostra a tabela 5.5. O mesmo ocorre com o conjunto de dados integral do depósito que, após a retificação de 7 valores de ouro a 3,5 g/t, reduziu o coeficiente de variação a 180%, índice considerado ‘comportado’ para depósitos auríferos.

Tabela 5.5 – Medidas estatísticas resumo dos teores de cobre e ouro do bloco piloto *com e sem* valores extremos.

	N	Média	Mínimo	Máximo	Desvio Padrão	Coef. Variação
AUPPM <sup>1</sup>	6252	0.15	0.002	24.02	0.418	275%
CUPCT <sup>1</sup>	6252	0.19	0.005	6	0.265	139%
AUPPM <sup>2</sup>	6247	0.15	0.002	3.59	0.284	192%
CUPCT <sup>2</sup>	6247	0.19	0.005	2.3	0.235	125%

1: Com valores extremos.

2: Sem valores extremos (AUPPM < 4ppm e CUPCT < 3%)

As distribuições de frequência das variáveis de concentração metálica representadas nos histogramas da figura 5.8 são lognormais com forte assimetria positiva, como esperado em variáveis que medem a concentração de elementos menores. As curvas de probabilidade mostradas na figura 5.9 confirmam o comportamento lognormal dos teores de cobre e ouro, assim como

auxiliam na identificação dos valores anômalos do quartil superior representados por pontos isolados na extremidade direita da curva de probabilidade. Adotando este critério poderíamos fixar como os limites para valores extremos em 3,0 % para os teores de cobre e 4,0 g/t para os teores de ouro. Somente 5 registros extrapolam esses limites, representando 0,08% do banco de dados piloto. Na avaliação econômica do depósito os teores acima de 2,5 % para cobre e 3,5 g/t para ouro foram retificados a estes limites, afetando tão somente 7 registros de ouro e 5 de cobre em um conjunto de dados com aproximadamente 36.000 amostras.

Os valores extremos podem expressar erros de amostragem ou simplesmente “efeito pepita”; qualquer que seja a causa deve ser considerada a sua exclusão ou retificação, haja visto o impacto dos mesmos nos parâmetros estatísticos. Entretanto há uma diversidade de métodos e critérios para identificação de valores anômalos e extremos e a adoção de um deles depende da aplicação requerida.




Figura 5.8 – Histogramas de frequência das variáveis de concentração metálica: teores de cobre e ouro. Teste de normalidade.




Figura 5.9 – Gráficos de probabilidade lognormal da distribuição cumulativa dos teores de cobre e ouro. Valores extremos a serem expurgados ou retificados.

A correlação de todas as variáveis entre si e, principalmente entre as variáveis de concentração metálica e as demais é uma aspecto fundamental da etapa de conhecimento do problema a ser tratado pelas redes neurais. Durante os trabalhos de exploração os geólogos do projeto adquiriram uma noção qualitativa da relação dos atributos geológicos e geotécnicos com a mineralização. Além de relações óbvias, como a quantidade de calcopirita e o teor de cobre, foram notadas outras mais discretas como, por exemplo: a relação de maior frequência de fraturas com zonas mineralizadas, a de zonas com intensa alteração hidrotermal com teores altos e da preferência da mineralização por determinadas litologias como os biotita xistos.

No intuito de quantificar as correlações entre as variáveis montaram-se matrizes de correlação linear. A tabela 5.6 apresenta o coeficientes de Pearson calculado para cada par de variáveis utilizando todos os registros do banco piloto ( $n=6252$ ) e destacando aqueles coeficientes significativamente diferentes de zero, ou seja, indicando a existência de associação entre as variáveis. As associações destacadas foram detectadas pelo teste de correlação linear como rejeição da hipótese de correlação nula, não significando entretanto que exista uma correlação expressiva entre as variáveis. A probabilidade de rejeição da hipótese nula aumenta com o número de dados ( $n$ ), pois o coeficiente de correlação tabular ( $r$ ) é inversamente proporcional a  $n$ , e quando  $n$  se aproxima de 100,  $r$  se torna muito pequeno. No conjunto de dados do presente estudo a rejeição da hipótese nula não diz nada sobre a força da correlação entre as variáveis medidas.

Os coeficientes de correlação mais elevados provêm dos pares das variáveis “AUPPM” - “CUPCT” (0,67), “CP\_PY” - “CUPCT” (0,50), “CP\_PY” - “AUPPM” (0,37) e “RQD” -

“FRACT” (- 0,21). A correlação positiva regular entre teores de ouro e cobre advém do fato de que no depósito de Chapada os dois metais freqüentemente são hospedados pelo mesmo mineral: a calcopirita. Pelo mesmo motivo a correlação entre a razão calcopirita/pirita e teores de cobre e ouro é medianamente positiva. A correlação inversa entre RQD e freqüência de fraturas, comentada anteriormente nesta seção, surpreendeu pela magnitude do coeficiente que se esperava mais elevado.

É sabido que o coeficiente de correlação pode ser afetado positiva ou negativamente por pares de valores extremos. Para testar esse efeito no banco piloto a matriz de correlação foi reconstruída excluindo os cinco registros contendo valores extremos de cobre e ouro (tabela 5.7). Houve uma melhora significativa na correlação entre teores de cobre e ouro: o coeficiente saltou de 0,67 para 0,85, valor este considerado elevado. Outro salto qualitativo ocorreu com a correlação positiva entre a razão calcopirita/pirita e teor de ouro, passando de fraca (0,37) a mediana (0,51).

O coeficiente de correlação pode ser um parâmetro estatístico inexpressivo caso o relacionamento entre as variáveis seja não linear. Uma técnica para suprir o coeficiente de Pearson com outra medida de intensidade da relação entre duas variáveis é o coeficiente de correlação ordenado (coeficiente de Spearman) (Isaaks e Srivastava, 1989). Consiste em aplicar na equação de Pearson a ordem de classificação dos valores de cada variável ao invés dos próprios valores. Os valores de cada variável são classificados em ordem ascendente e o menor valor recebe a classificação “1” e o maior recebe a classificação  $n$ ; a média e desvio padrão são calculados com as classificações. A técnica tem a vantagem de reduzir a influência de valores erráticos e detectar relacionamentos não lineares.

A tabela 5.8 exhibe a matriz de correlação ordenada com destaque para os coeficientes que apresentaram variação digna de nota em relação às matrizes anteriores. Houve redução do coeficiente de correlação entre a variável “SULPCT” (porcentagem de sulfetos) e as variáveis “CUPCT” e “AUPPM”, teores de cobre e ouro, respectivamente. Por outro lado, a correlação se fortaleceu entre a variável “RQD” e as variáveis teores de cobre e ouro, silicificação (“SILIC”) e razão calcopirita/pirita (“CP\_PY”). Observa-se ainda um discreto incremento do coeficiente de correlação entre algumas variáveis de alteração hidrotermal, reforçando em uma tendência insinuada nas matrizes anteriores. Existe uma correlação negativa entre as frentes de cloritização e piritização (-0,24) e ao mesmo tempo positiva entre cloritização, silicificação e carbonatização, ou seja, estas caminham juntas enquanto aquelas tendem ao antagonismo.

Tabela 5.6 – Matriz de coeficientes de correlação linear de Pearson ( $n=6252$ ). Destacados os coeficientes significativamente diferentes de zero.

Variáveis	CHLORI	SERICI	SILICI	EPIDOT	CARBON	PYRIT	CP_PY	SULPCT	FRACT	RQD	AUPPM	CUPCT
CHLORI	1.00											
SERICI	<b>0.08</b>	1.00										
SILICI	<b>0.12</b>	<b>0.07</b>	1.00									
EPIDOT	<b>0.09</b>	<b>-0.03</b>	0.01	1.00								
CARBON	<b>0.16</b>	<b>0.13</b>	<b>0.18</b>	<b>0.06</b>	1.00							
PYRIT	<b>-0.19</b>	<b>0.10</b>	<b>-0.09</b>	-0.02	<b>0.08</b>	1.00						
CP_PY	<b>-0.11</b>	<b>-0.03</b>	<b>-0.09</b>	<b>0.05</b>	<b>-0.05</b>	<b>0.17</b>	1.00					
SULPCT	-0.01	0.00	<b>-0.05</b>	-0.01	<b>0.04</b>	<b>0.03</b>	<b>0.28</b>	1.00				
FRACT	<b>-0.14</b>	<b>-0.07</b>	<b>-0.12</b>	<b>0.04</b>	<b>-0.11</b>	<b>0.06</b>	<b>0.09</b>	-0.01	1.00			
RQD	<b>0.11</b>	<b>-0.03</b>	<b>0.10</b>	0.00	<b>0.12</b>	-0.02	<b>-0.06</b>	<b>0.03</b>	<b>-0.21</b>	1.00		
AUPPM	<b>-0.03</b>	<b>0.04</b>	0.00	-0.01	0.00	0.02	<b>0.37</b>	<b>0.16</b>	0.00	<b>-0.03</b>	1.00	
CUPCT	-0.02	<b>0.06</b>	-0.02	-0.02	0.01	0.02	<b>0.50</b>	<b>0.19</b>	0.02	<b>-0.05</b>	<b>0.67</b>	1.00

Tabela 5.7 – Matriz de coeficientes de correlação linear de Pearson calculados sem valores extremos. ( $n=6247$ ). Destacados os coeficientes significativamente diferentes de zero.

Variáveis	CHLORI	SERICI	SILICI	EPIDOT	CARBON	PYRIT	CP_PY	SULPCT	FRACT	RQD	AUPPM	CUPCT
CHLORI	1.00											
SERICI	<b>0.08</b>	1.00										
SILICI	<b>0.12</b>	<b>0.07</b>	1.00									
EPIDOT	<b>0.09</b>	<b>-0.03</b>	0.01	1.00								
CARBON	<b>0.16</b>	<b>0.13</b>	<b>0.18</b>	<b>0.06</b>	1.00							
PYRIT	<b>-0.19</b>	<b>0.10</b>	<b>-0.09</b>	-0.02	<b>0.08</b>	1.00						
CP_PY	<b>-0.11</b>	<b>-0.03</b>	<b>-0.09</b>	<b>0.05</b>	<b>-0.05</b>	<b>0.16</b>	1.00					
SULPCT	0.00	0.00	<b>-0.05</b>	-0.01	<b>0.05</b>	<b>0.03</b>	<b>0.28</b>	1.00				
FRACT	<b>-0.14</b>	<b>-0.07</b>	<b>-0.12</b>	<b>0.04</b>	<b>-0.11</b>	<b>0.06</b>	<b>0.09</b>	-0.01	1.00			
RQD	<b>0.11</b>	<b>-0.03</b>	<b>0.09</b>	0.00	<b>0.12</b>	-0.02	<b>-0.06</b>	<b>0.03</b>	<b>-0.21</b>	1.00		
AUPPM	<b>-0.03</b>	<b>0.04</b>	-0.02	-0.01	0.02	0.00	<b>0.51</b>	<b>0.18</b>	0.01	<b>-0.03</b>	1.00	
CUPCT	<b>-0.03</b>	<b>0.06</b>	-0.02	-0.02	0.00	0.01	<b>0.57</b>	<b>0.21</b>	0.01	<b>-0.05</b>	<b>0.85</b>	1.00

Tabela 5.8 – Matriz de coeficientes de correlação de Spearman. ( $n=6247$ ). Destaque para variações expressivas em relação a tabela 5.6.

Variáveis	CHLORI	SERICI	SILICI	EPIDOT	CARBON	PYRIT	CP_PY	SULPCT	FRACT	RQD	AUPPM	CUPCT
CHLORI	1.00											
SERICI	0.08	1.00										
SILICI	0.18	0.07	1.00									
EPIDOT	0.10	-0.02	0.01	1.00								
CARBON	0.17	0.13	0.21	0.06	1.00							
PYRIT	-0.24	0.06	-0.13	0.00	0.07	1.00						
CP_PY	-0.14	-0.04	-0.11	0.07	-0.04	<u>0.23</u>	1.00					
SULPCT	-0.01	0.02	-0.05	-0.03	0.06	<u>0.12</u>	0.28	1.00				
FRACT	-0.14	-0.08	-0.12	0.05	-0.11	0.09	0.11	0.01	1.00			
RQD	0.10	0.05	<u>0.17</u>	-0.01	0.14	-0.08	<u>-0.14</u>	-0.03	-0.27	1.00		
AUPPM	-0.01	0.03	-0.04	0.00	0.03	0.03	0.52	<u>0.09</u>	0.01	<u>-0.13</u>	1.00	
CUPCT	-0.01	0.06	-0.04	-0.02	0.04	0.05	0.56	<u>0.13</u>	0.03	<u>-0.14</u>	0.84	1.00

As variações entre os coeficientes de Spearman e Pearson são em sua maioria, oriundas principalmente da influencia acentuada de alguns pares de valores erráticos extremos positivos ou negativos no coeficiente linear (Pearson). Em alguns casos, o incremento do coeficiente de Spearman em relação ao de Pearson pode ser um indício de correlação não linear entre as variáveis.

Por último, para avaliar a correlação entre litologias e concentração metálica procedeu-se primeiro a decomposição da variável “LITHO” em uma matriz binária de 6247 x 11, onde cada coluna foi ocupada por uma litologia específica cujos registros são “0” (inexistente) ou “1” (existente), lembrando que cada amostra admite no máximo um tipo litológico. A matriz de correlação foi montada com as variáveis da matriz litológica e os teores de cobre e ouro (tabela 5.9). Embora em valores absolutos os coeficientes de correlação sejam baixos é possível concluir a partir da comparação dos resultados que: existe uma relação preferencial entre a mineralização e os biotita xistos e um tendência de teores mais baixos nos demais tipos de rocha. Os gráficos box-plot apresentados na figura 5.10 confirmam os xistos à biotita como o grupo litológico mais mineralizado em ouro e cobre, destacando os biotita-quartzo xistos como hospedeiras dos teores mais elevados. Outros tipos litológicos tais como anfíbolito, pegmatito, microgranodiorito apresentam mediana de teores próximo a zero, refletindo a posicionamento geológico dessas rochas como capa do minério ou intrusões estéreis a fracamente mineralizadas. Entre os grupos de xistos à biotita e anfíbólio existe a grosso modo, uma equalização de medianas, simetrias e variabilidades de teores de cobre e ouro, sugerindo tratar-se de um mesmo domínio estatístico. É possível portanto, a partir do gráfico separar dois grandes domínios estatísticos, que correspondem ao corpo mineralizado e as encaixantes estéreis.

Tabela 5.9 – Correlação linear entre litologia e teores de cobre e ouro.

LITHO	Descrição	AUPPM	CUPCT
RT_0	Solo, saprolito, rocha intemperizada	-0.01	0.01
RT_10	Biotita xisto	<b>0.08</b>	<b>0.12</b>
RT_15	Biotita cianita xisto	0.03	0.01
RT_18	Biotita Qtzo xisto	0.01	0.01
RT_20	Antofilita xisto	-0.02	-0.01
RT_25	Anfíbólio xisto	-0.06	-0.08
RT_30	Anfíbolito	-0.03	-0.04
RT_35	Anfíbolito bandado	-0.04	-0.05
RT_80	Pegmatito	-0.07	<b>-0.10</b>
RT_100	Metatufo	-0.03	-0.02
RT_300	Micro granodiorito	-0.03	-0.05





Figura 5.10 – Gráfico *box-plot* das variáveis teor de cobre (A) e teor de ouro (B) categorizadas por litologia.

De um modo geral a análise de correlação confirmou os relacionamentos óbvios entre a mineralização e razão calcopirita/pirita, RQD e grau de fraturamento, teores de cobre e ouro, e revelou outros mais sutis tais como a associação entre fraturamento e cloritização. O relacionamento preferencial entre biotita xistos e a mineralização, já reportado nas descrições geológicas, foi numericamente comprovado. Apesar de todas estas observações nenhuma das correlações, com exceção do par teores de cobre e ouro, é forte o suficiente para sustentar individualmente uma análise de regressão satisfatória. À exceção anteriormente citada, o coeficiente de determinação ( $r^2$ ) das associações analisadas situa-se muito aquém de 0,50, valor mínimo para que a associação entre duas variáveis seja considerada significativa.

#### **5.4 Análise geoestatística dos teores de cobre e ouro**

Embora a aplicação da técnica de redes neurais não exija a adoção de premissas relativas à distribuição espacial das variáveis, o estudo da localização e variabilidade dos teores de cobre e ouro no depósito de Chapada é imprescindível para o conhecimento e caracterização da mineralização. O comportamento tridimensional da mineralização foi avaliado por meio da análise geoestatística dos dados de teores de cobre e ouro das amostras de sondagem e suas respectivas coordenadas espaciais, registradas em um sistema local arbitrário. Neste sistema referencial local, obtido através da rotação e translação do sistema de coordenadas geográficas real, o eixo “X” alinha-se na direção leste-oeste, o eixo “Y” na direção norte-sul e o eixo “Z” na direção vertical. Aplicam-se aos eixos escalas métricas ascendentes nos rumos leste (“X”), norte (“Y”) e descendente na vertical (“Z”), onde assume os valores absolutos de elevação em relação ao nível médio do mar.

Baseado na análise estatística e observações da distribuição espacial dos teores de cobre e ouro assume-se a hipótese de estacionaridade das variáveis em um modelo probabilístico, presumindo uma certa continuidade espacial regida por processos aleatórios.

A variabilidade espacial dos teores foi analisada através de semi-variogramas absolutos e relativos construídos ao longo de direções e domínios estabelecidos pela modelagem geológica do depósito. A mineralização foi modelada em três dimensões gerando dois envelopes geológicos individuais denominados: “corpo principal”, abrangendo a maior parte dos recursos minerais, e “corpo nordeste”, com menor volume. O corpo principal apresenta uma geometria de antifórma e, para detalhar as diferentes orientações estruturais, foi subdividido em três partes: “zona 1”, correspondente ao flanco sul da estrutura; “zona 2”, correspondente a zona apical; e “zona 3”

correspondente ao flanco norte. O corpo nordeste foi renomeado como “zona4”. (figura 5.11). Entretanto o número de dados das subdivisões do corpo principal não foi suficiente para produzir bons variogramas e assim, optou-se por tratá-los como um todo na análise variográfica deixando para a etapa de krigagem o ajuste das diferentes orientações dos raios de amplitudes correlacionáveis (figura 5.12). Os dados amostrais localizados fora dos envelopes mineralizados foram agrupados em um único domínio variográfico denominado “zona estéril”. As figuras 5.13 e 5.14 mostram os semi-variogramas direcionais dos teores de ouro e cobre respectivamente, obtidos nos diferentes domínios geológicos utilizando a biblioteca de programas *GSLIB* (Deutsch & Journel, 1992). Os parâmetros variográficos oriundos da modelagem esférica dos variogramas experimentais são apresentados na tabela 5.10.

Tabela 5.10- Índices variográficos das diferentes zonas do depósito de Chapada.

Zona	Metal	Azimute / Mergulho			Alcance (metros)			Efeito pepita	Patamar
		eixos ajustados			eixos				
		Maior	Médio	Menor	Maior	Médio	Menor		
1	ouro	90/ 0	180 /-10	180/+80	200	100	40	0,005	0,062
	cobre	90/0	180 /-10	180/+80	150	100	40	0,005	0,052
2	ouro	90/ 0	0/0	90/+90	200	100	40	0,005	0,062
	cobre	90/0	0/0	90/+90	150	100	40	0,005	0,052
3	ouro	90/ 0	0/-15	0/+75	200	100	40	0,005	0,062
	cobre	90/0	0/-15	0/+75	150	100	40	0,005	0,052
4	ouro	80/0	350/ 0	350/+90	250	150	35	0,05	0,48
	cobre	240/-10	350/ 0	240/+80	250	130	35	0,05	0,20
‘estéril’	ouro	90/0	0/0	90/+90	200	110	70	0,005	0,045
	cobre	105/0	15/0	15/+90	140	110	55	0,005	0,048

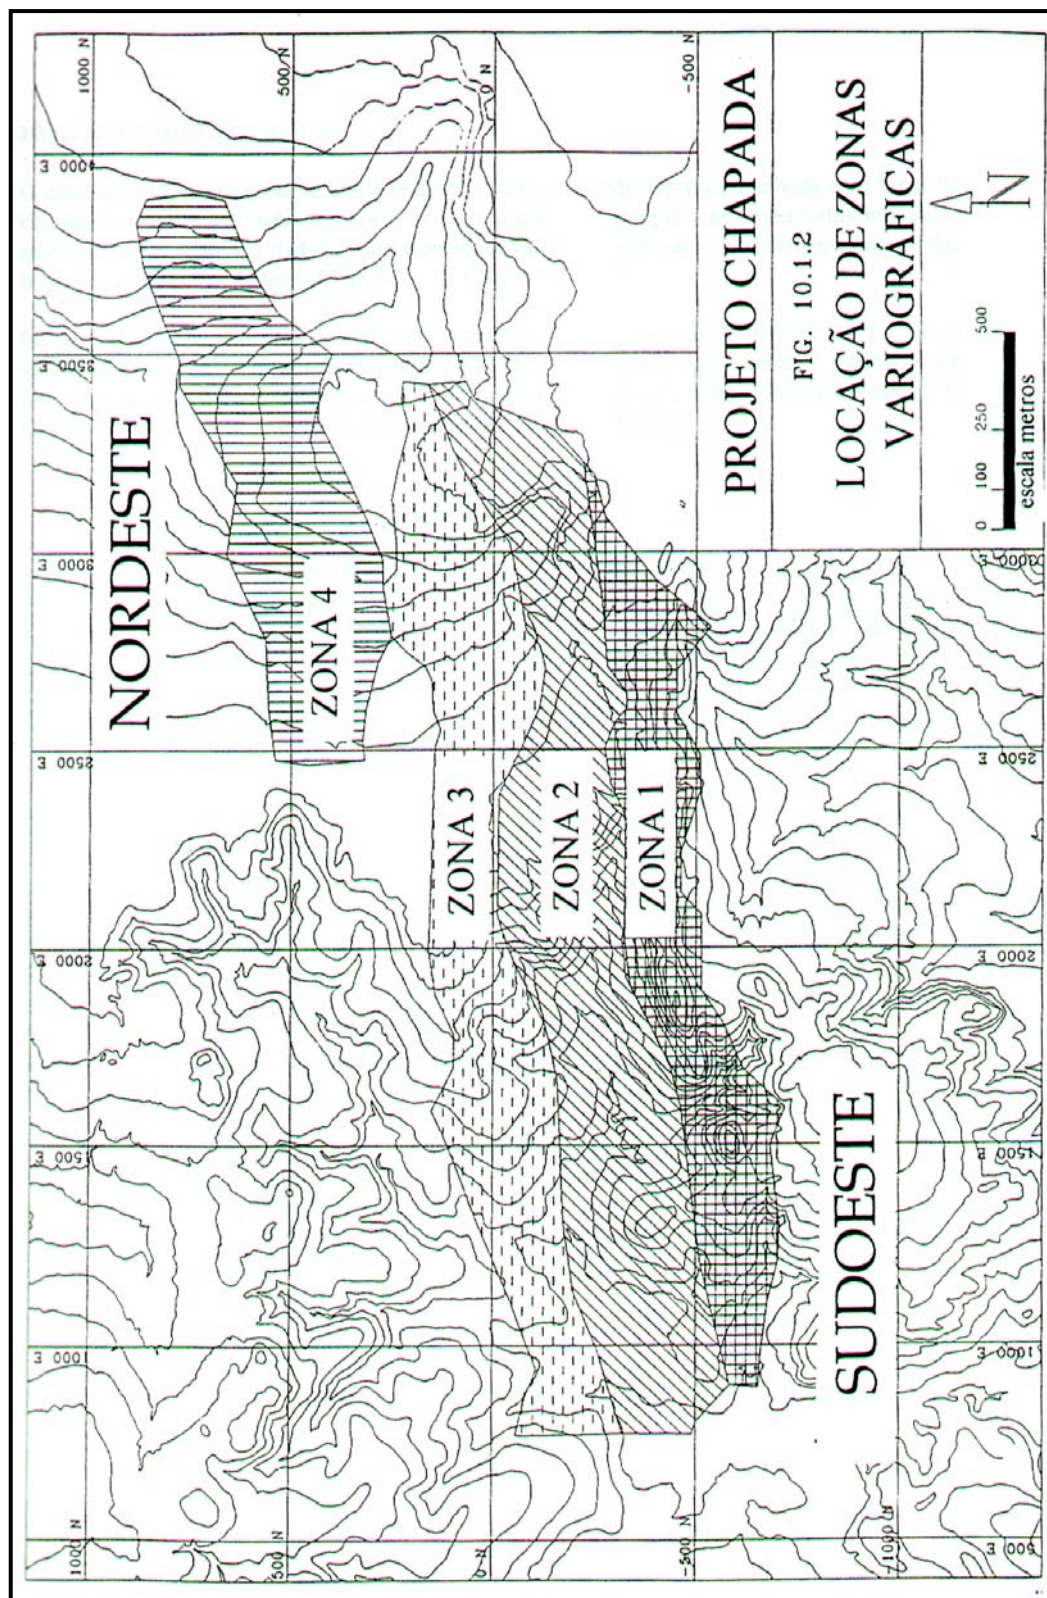


Figura 5.11 – Compartimentação do depósito de Chapada em domínios variográficos. (modificado de Mineração Alonte Ltda. 1997)




Figura 5.12 – Orientação dos elipsóides variográficos nas zonas 1, 2 e 3 do corpo principal.

Com exceção do eixo médio da zona 4 (corpo nordeste), os variogramas exibem boa estruturação, baixo efeito pepita, e longo alcance tanto para os teores de cobre quanto de ouro. As amplitudes variográficas (alcances) obtidos nos três eixos variográficos são perfeitamente coerentes com a anisotropia geológica do depósito, confirmando a maior continuidade na direção do alongamento dos corpos e a menor continuidade paralela ao mergulho do plano axial da antifforma. É notável a continuidade dos teores de ouro na direção principal (eixo maior) do depósito, estimada em 200 metros, muito superior a maioria dos depósitos auríferos. A razão para tal continuidade é a forma de ocorrência do ouro, predominantemente associado a calcopirita, o principal mineral de minério de cobre, que costuma apresentar elevada continuidade espacial em depósitos de sulfeto disseminado.

Uma vez conhecida a variabilidade espacial da mineralização através da análise variográfica, a estimativa geoestatística dos teores de ouro e cobre em locais não amostrados permitiu a visualização da distribuição espacial das variáveis. Considerando a adequação ao modelo probabilístico e a variabilidade medida, a krigagem ordinária é um método de estimativa apropriado ao caso em estudo. Para a aplicação do método, um modelo de blocos tridimensionais foi construído com o auxílio do “software” *Vulcan 3.2* (1998), com unidades de tamanho 10m x 10m orientadas nas direções leste-oeste e norte-sul e 5m na vertical, totalizando 6,7 milhões de

blocos. Procedeu-se ainda a composição dos teores originais oriundos de intervalos amostrais de 1,5m em compósitos de 5m, com a finalidade de reduzir a demanda computacional e a variabilidade devido a erros sistemáticos de amostragem. A estimativa dos teores de cada bloco foi executada pela krigagem ordinária utilizando os parâmetros variográficos apresentados na tabela 5.10. Os raios de procura foram diferenciados para cada zona do modelo geológico, girando em torno de 200x100x40m (X,Y,Z) para teores de ouro e 150x100x40m para cobre. Nas áreas de alto teor ( $Au > 1 \text{ g/t}$ ,  $Cu > 1 \%$ ) os raios foram reduzidos para 30x30x10m. Considerando que o raio de procura é quase três vezes maior que a rede de amostragem (50x25x5m) restringiu-se a estimativa de cada bloco a um mínimo de 3 e um máximo de 10 amostras, limitadas ao máximo de 3 amostras por furo de sondagem. Este procedimento visa minimizar a suavização dos valores estimados, característica da krigagem ordinária.

A curva de distribuição dos valores estimados pela krigagem comparada à distribuição dos valores amostrados através de gráfico de frequência cumulativa (figura 5.15) apresenta um ajuste satisfatório da estimativa. Entretanto persiste o efeito de “suavização” da krigagem ordinária, o que pode acarretar dano potencial na quantificação do conteúdo metálico do depósito através da superestimativa dos teores baixos e da subestimativa dos teores altos. Considerando que o número de blocos com baixos teores é muito superior ao número de blocos com altos teores, a tendência é superestimar o conteúdo metálico do depósito. A aplicação de estimativas regionalizadas em subdomínios ou mesmo de krigagem por indicadores pode amenizar este risco. A figura 5.16 apresenta uma seção horizontal do modelo de blocos mostrando a distribuição espacial dos teores de cobre no depósito de Chapada.


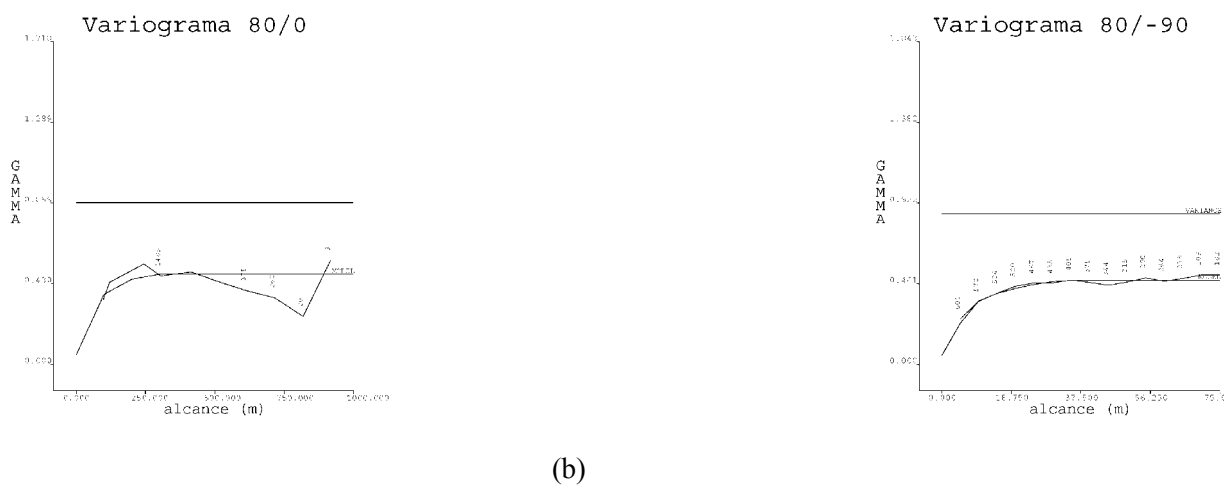
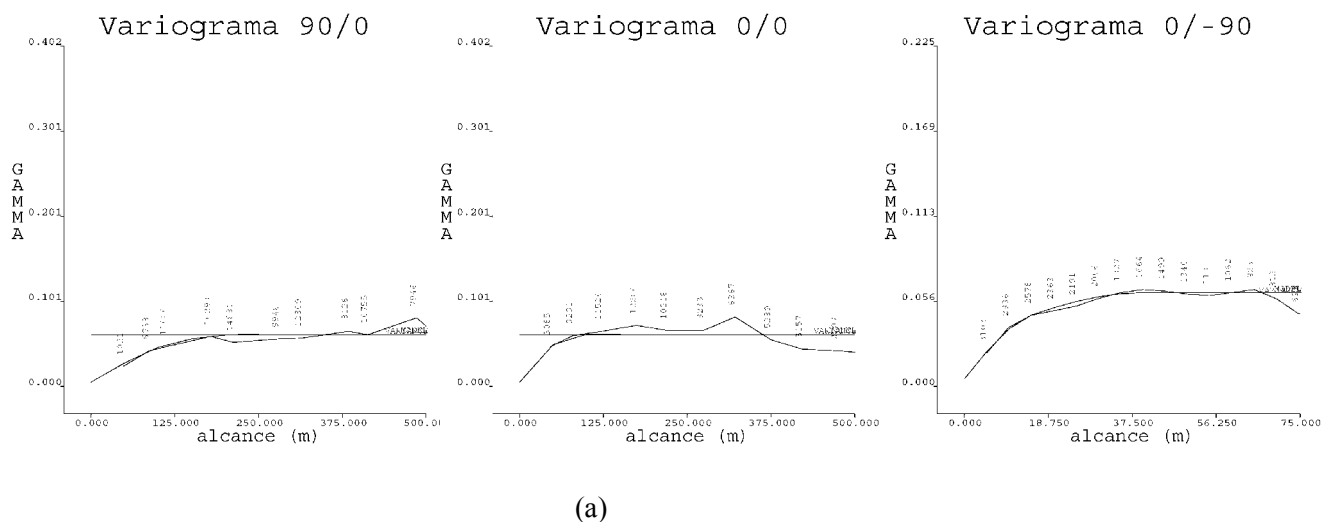




Figura 5.13 – Variogramas direcionais dos teores de ouro no corpo principal (a), no corpo nordeste (b) e fora dos corpos de minério (c).



(a)



(b)



(c)

Figura 5.14 – Variogramas direcionais dos teores de cobre no corpo principal (a), no corpo nordestee (b) e fora dos corpos de minério (c).




Figura 5.15 – Gráfico de probabilidade dos valores amostrados comparados com os valores estimados pela krigagem ordinária.




Figura 5.16 – Vista tridimensional de seção horizontal do modelo de blocos com teores de cobre estimados por krigagem ordinária, mostrando concentração de teores elevados na zona apical da antiforma (zona central).

## 5.5 Modelagem proposta para as redes neurais

A aplicação da técnica de modelagem proposta compõe-se das seguintes etapas: preparação dos dados, criação da rede neural (arquitetura), treinamento da rede, validação e teste de generalização. Estas etapas foram exaustivamente repetidas com alterações dos diversos parâmetros até obter a configuração de rede com o melhor desempenho.

A etapa inicial consistiu na preparação do conjunto de dados piloto (“bloco 1”) segundo os passos abaixo descritos:

1. A variável categórica “LITHO” foi decomposta em 13 variáveis binárias correspondentes aos diferentes tipos litológicos do depósito, sendo valor “0” para inexistente e valor “1” para existente. Assim a matriz integral de 6.252 registros por 13 variáveis transformou-se em uma matriz 6.252 x 25;
2. Divisão da matriz 6.252 x 25 em duas: matriz de dados de entrada (“entrada”) com 6.252 x 23 (21 variáveis geológicas e 2 geotécnicas) e matriz de saída (“saída”) 6.252 x 2 (teores de ouro e cobre);
3. Exclusão de duas variáveis (códigos “90” e “110”) com variância zero da matriz “entrada” referentes aos tipos litológicos veios de quartzo e sericita quartzo xisto, ausentes no bloco piloto;
4. Transposição das matrizes para entrada no software MatLab 6.0;
5. Normalização dos dados das matrizes “entrada” e “saída” para o intervalo [-1,1], usando a equação:  $x_n = (2(x - x_{min})) / (x_{max} - x_{min}) - 1$  ;
6. Divisão das matrizes para criação dos subconjuntos de treinamento, validação e teste, com 75%, 20% e 5% dos dados, respectivamente. Resultaram 6 matrizes: 3 “entradas” com tamanho 21x 4.689, 21x 1.250 e 21x 313, e 3 correspondentes “saídas” com tamanho 2 x 4.689, 2 x 1.250, e 2x 313.

A mesma rotina acima descrita foi seguida na preparação dos conjuntos de dados pertencentes aos blocos “2”, “3” e “4”.

A normalização dos dados realizada no passo “5” visa tornar o intervalo de entrada da rede mais compatível com as funções de ativação que trabalham com intervalos restritos. Não é um procedimento indispensável porém altamente recomendável para tornar mais eficiente o treinamento da rede. Todas as saídas e parâmetros da rede estarão na forma normalizada e, para facilitar a interpretação deverão ser convertidos de volta à escala original.

A segunda etapa consiste na seleção da arquitetura da rede neural, com a definição do número de camadas, respectivos número de neurônios e seleção das funções de ativação para cada camada.

Optou-se pela arquitetura de rede com múltiplas camadas (MLP) alimentada adiante por sua habilidade em aproximar funções arbitrárias que têm sido aplicadas com sucesso na solução de diversos problemas difíceis, notadamente no campo da geotecnia e engenharia.

O número de camadas da rede foi fixado inicialmente em três: uma camada de entrada, uma camada oculta e uma camada de saída. A justificativa para isso é de ordem prática: deve-se partir da configuração mais reduzida e, se o problema exigir maior complexidade, aumenta-se o número de camadas. Adicionalmente, sabe-se que grande parte dos problemas de engenharia, do tipo mapeamento entrada-saída, podem ser analisados através de redes de apenas uma camada escondida (Haykin, 2001). Existe ainda um teorema provando que uma rede neural alimentada adiante com três camadas é capaz de aproximar qualquer função contínua (Hecht-Nielsen in Denby & Burnett, 1995).

O número de neurônios da rede foi assim determinado :

- camada de entrada: número de neurônios igual ao número de variáveis de entrada
- camada oculta: inicialmente 22 neurônios (aproximadamente igual a camada de entrada), depois variado para 12 e 33;
- camada de saída: 2 neurônios, referentes aos teores de ouro e cobre.

Foram testadas nos treinamentos as seguintes funções de ativação: logística ou tangente hiperbólica na camada oculta e linear ou linear saturada na camada de saída. Optou-se por funções sigmóides na camada oculta pela capacidade de servirem indistintamente a relações funcionais lineares ou não-lineares entre as variáveis de entrada e saída da rede a ser treinada. A escolha de funções lineares na saída da rede deve-se a melhor compatibilidade com a normalização linear aplicada aos dados. A função linear pura aceita saídas fora do intervalo  $[-1,1]$  enquanto que a função saturada restringe-se a este, o que é particularmente útil para evitar que as saídas da rede (teores de cobre e ouro) ao serem “desnormalizadas” apresentem valores negativos.

Segundo Haykin (2001) uma rede MLP pode aprender mais rápido (em termos de número de iterações de treinamento necessárias) quando a função de ativação sigmóide for antissimétrica, leia-se função tangente hiperbólica. Se a função de ativação for não-simétrica, como no caso da função logística, a saída de cada neurônio está restrita ao intervalo  $[0,1]$  introduzindo uma fonte de *viés sistemático* para aqueles neurônios localizados além da primeira camada oculta da rede. Com a escolha da função tangente hiperbólica permite-se que a saída de cada neurônio assuma valores

tanto positivos quanto negativos no intervalo  $[-1,1]$ , e neste caso é provável que a sua média seja zero, produzindo uma convergência mais rápida do algoritmo de aprendizagem (retropropagação). A figura 5.17 mostra um diagrama esquemático da arquitetura da rede criada.

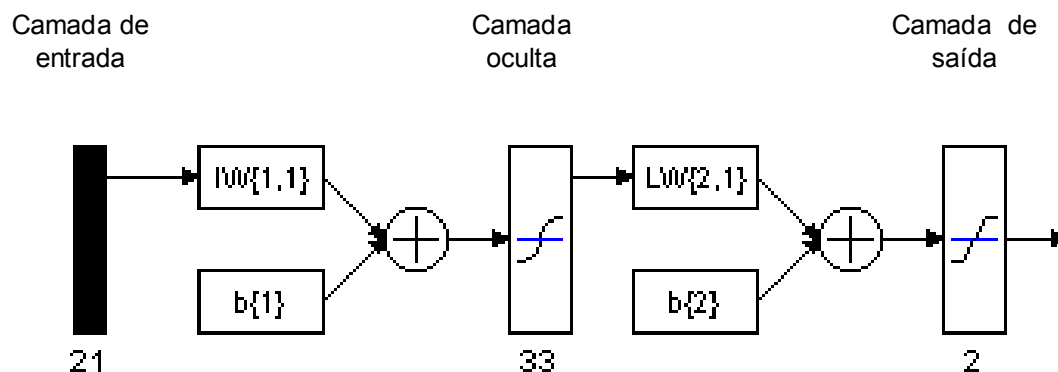


Figura 5.17 - Diagrama da arquitetura da rede neural com elementos: camada de entrada c/ 21 neurônios; uma camada oculta c/ 33 neurônios e função de ativação sigmóide; camada de saída c/ 2 neurônios; viés (b), matriz de pesos de entrada (IW), matriz de pesos de camada oculta (LW).

Com os dados preparados e os parâmetros da rede definidos segue-se a etapa de treinamento ou aprendizagem da rede onde são ajustados os pesos sinápticos das conexões neuronais de maneira iterativa através da minimização do erro entre a saída real e a saída desejada. Para realizar esta tarefa foi escolhido o algoritmo de retropropagação de erro Levenberg-Marquardt (LM) descrito no capítulo 2. O treinamento foi realizado no módulo de redes neurais (“Neural Network Toolbox”) versão 4 do software MatLab 6.0.

O ponto de encerramento da sessão de treinamento é um aspecto crítico da aplicação da técnica de redes neurais, pois um ajuste excessivo aos dados do conjunto de treinamento (“overtraining”) pode comprometer a capacidade de generalização da rede. Para evitar o treinamento excessivo foi aplicado no monitoramento da aprendizagem o *método da parada antecipada* (“early stopping”) descrito em detalhes no capítulo 2. No presente caso o subconjunto de dados de treinamento foi usado para computar o gradiente e atualizar os pesos sinápticos e viéses. O erro do subconjunto de validação foi também monitorado durante o processo de treinamento. Este erro normalmente decresce na fase inicial de treinamento, assim como o erro do subconjunto de treinamento. Entretanto, quando a rede começa a ajustar excessivamente os dados, o erro do subconjunto de validação tipicamente começa a aumentar. Nesse ponto mínimo da curva de validação a sessão de treinamento é encerrada. O subconjunto de teste não participa da validação cruzada mas é plotado no gráfico de monitoramento do processo de treinamento. Se o erro do subconjunto de teste atingir o valor mínimo em tempo significativamente diferente (medido em

número de iterações) do subconjunto de validação isto pode indicar uma divisão inadequada do conjunto de dados.

Depois de encerrada a sessão de treinamento as saídas da rede foram “desnormalizadas” de volta à escala original para comparação com os dados reais. Essa comparação foi feita através de plotagem em gráfico de dispersão e análise de regressão linear.

O teste de generalização utilizou o subconjunto de teste (5% do conjunto de dados) cujas variáveis geológicas e geotécnicas foram imputadas na rede neural já treinada num processo denominado *simulação*. As saídas da rede neural resultantes da simulação foram comparadas com os valores reais (teores de ouro e cobre) em gráficos de dispersão e análise de regressão linear. Nem sempre o melhor desempenho no treinamento conduz à melhor generalização como será mostrado na seção seguinte.

O processo de otimização da técnica iniciou-se com a seleção de uma configuração de rede estável com desempenho satisfatório tanto no treinamento quanto na generalização do conjunto de dados piloto. Uma vez zerados os pesos sinápticos desta rede, a mesma foi alimentada com os dados geológicos acrescidos das respectivas coordenadas espaciais (“X”, “Y” e “Z”) das amostras contidas nos blocos “1”, “2”, “3” e “4” e submetida a sessões individualizadas de treinamento, validação e teste de generalização. Por último aplicou-se ao algoritmo de treinamento Levenberg-Marquardt a função de regularização bayesiana descrita no capítulo 2, e comparou-se o desempenho das redes na aprendizagem e na sua capacidade de generalização.

Para a avaliação final da capacidade de predição da rede otimizada foram plotadas uma seção completa de sondagem de cada bloco comparando os valores reais para os teores de cobre e ouro com as saídas da rede.

Procedeu-se por último a avaliação do peso de cada variável na capacidade preditiva da rede neural otimizada, seguido de um exercício de redução das variáveis redundantes.

## **5.6 Apresentação e discussão dos resultados**

### **5.6.1 Aplicação piloto**

Nesta seção serão apresentados os resultados dos treinamentos e testes de generalização das redes neurais alimentadas com o conjunto de dados piloto oriundo do bloco “1”. Manteve-se fixo o número de camadas das redes (1 camada oculta) e foram testadas as seguintes hipóteses: conjunto de dados com e sem valores extremos, variação do número de neurônios na camada oculta,

mudança de função de ativação da camada oculta, exclusão de variáveis de entrada com baixa correlação com a saída e exclusão de variáveis geotécnicas. O algoritmo de retropropagação utilizado no treinamento foi Levenberg-Marquardt. Ao final as configurações de rede com melhor desempenho no treinamento foram avaliadas com o subconjunto de teste de generalização.

Para facilitar a compreensão dos resultados os treinamentos foram reunidos em cinco grupos descritos a seguir:

1. Treinamento com conjunto de dados original (*com* valores extremos ) dividido em subconjuntos de: treinamento (N=4.687), validação (N=1.252) e teste (N=313). O número de neurônios da camada de entrada (variáveis geológicas e geotécnicas) foi fixado em 21, o da camada oculta em 30 e a camada de saída em 2 (teores de ouro e cobre). Funções de ativação: tangente hiperbólica na camada oculta e linear saturada na camada de saída. A figura 5.18 mostra a curva de aprendizagem com desempenho de todos os subconjuntos. A sessão foi encerrada em 23 iterações pelo *método da parada antecipada* (“early stopping”).

A medida padrão de desempenho do treinamento é o erro médio quadrático (*mse*) representado no eixo y das curvas de aprendizagem. A raiz do erro médio quadrático (*rmse*) uma vez “desnormalizada” representa também um erro percentual. Considerando que os dados utilizados foram normalizados no intervalo [-1,1] *rmse* é definido pela equação:

$$rmse = \frac{\sqrt{mse}}{2} \times 100\%$$




Figura 5.18 - Treinamento com valores extremos, 23 iterações, erro médio quadrático=0,0025. Azul: treinamento; Verde: validação; Vermelho: teste.

No treinamento atual o erro percentual é 2,5% , que indica um treinamento satisfatório. Entretanto, o gráfico de dispersão das saídas da rede *versus* valores reais (figura 5.19) para todos os subconjuntos revelou forte influencia do ajuste ruim dos pares de valores extremos resultando em fatores de correlação linear baixos: 0,51 para ouro e 0,49 para cobre.




Figura 5.19 - Gráfico de dispersão de saídas da rede (A) vs. valores reais (T) de teores de ouro (Au) e cobre (Cu). Redes com valores extremos.

2. Treinamentos com conjunto de dados sem valores extremos, onde foram excluídos cinco registros com valores extremos de cobre e ouro considerados erráticos (ver seção 5.3, figura 5.8). O conjunto foi redividido na mesma proporção (75-20-5%) gerando os subconjuntos de dados: treinamento (N=4.683), validação (N=1251) e teste (N=313). As redes foram treinadas com três diferentes números de neurônios na camada oculta: 30, 22 e 12. Foi testado também o impacto da mudança da função de ativação tangente hiperbólica para logística na camada oculta. A figura 5.20 ilustra os gráficos de desempenho das quatro redes.

Os resultados do treinamento apresentados na tabela 5.11 mostram que, em relação ao erro, as redes apresentam resultados muito próximos, tão próximos que não justificariam o número maior de neurônios na camada oculta, lembrando que isso significa mais tempo de processamento computacional. Contudo, o coeficiente de correlação linear entre as saídas

da rede e os valores reais melhora significativamente para a rede com 30 neurônios ocultos. O resultado do treinamento com a função logística não justifica a mudança da função de ativação na camada oculta. A figura 5.21 mostra o gráfico de dispersão de saídas da rede em relação aos valores reais de ouro e cobre para o treinamento com 30 neurônios.

Comparando os erros de treinamento *com* e *sem* valores extremos não é possível perceber benefício qualitativo no expurgo dos valores extremos. Considerando todavia, que esses valores representam 0,08% do banco de dados mas que exercem forte influência no coeficiente de correlação decidiu-se pela exclusão dos mesmos nos treinamentos a seguir.

Tabela 5.11 - Desempenho do treinamento de redes neurais sem valores extremos.

	No. de neurônios ocultos			Função 30-Logística
	30	22	12	
Erro (%) (treinamento)	5,9	6,3	6,7	4,9
Correlação Au	0,686	0,644	0,626	0,657
Correlação Cu	0,749	0,688	0,680	0,692




Figura 5.20 - Treinamento de redes neurais sem *valores extremos* com 30 (a), 22 (b), e 12 (c) neurônios ocultos; e mudança para função logística na camada oculta (d). (Azul: treinamento; Verde: validação; Vermelho: teste)




Figura 5.21 - Gráfico de dispersão de saídas da rede (A) vs. valores reais (T) de teores de ouro (Au) e cobre (Cu). Rede com 30 neurônios ocultos *sem* valores extremos.

3. Treinamento excluindo do conjunto de dados as variáveis geológicas que apresentaram baixa covariância com os teores de ouro e cobre. Foram mantidas no banco de dados as seguintes variáveis: litologias “10” (biotita xisto), “25” (anfíbolio xisto), “35” (anfíbolito bandado), “80” (pegmatito) e “300” (micro granodiorito); alterações hidrotermais: cloritização, sericitização e carbonatização; razão calcopirita/pirita; porcentagem de sulfetos; e variáveis geotécnicas (frequência de fraturas e RQD). Foi utilizada a mesma arquitetura de rede anterior (30 neurônios ocultos), alterando somente a camada de entrada que teve os nós de fonte reduzidos em função das variáveis excluídas.

Os gráficos ilustrados na figura 5.22 mostram um desempenho semelhante às redes anteriores no treinamento com erro igual a 6,9% porém inferior quando comparados os coeficientes de correlação, sugerindo a existência de correlações não lineares entre as concentrações metálicas e uma ou mais variáveis excluídas.

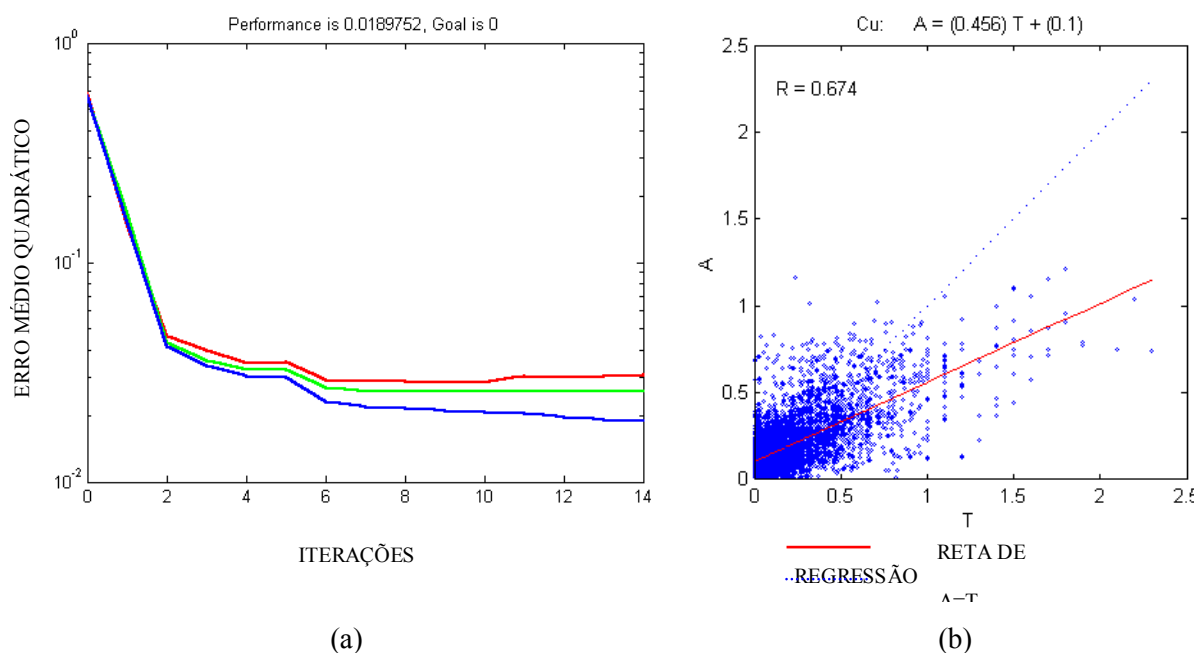


Figura 5.22 - (a) Curva de treinamento com variáveis geológicas selecionadas em função da covariância com teores de cobre (Azul: treinamento; Verde: validação; Vermelho: teste). (b) Gráfico de dispersão das saídas da rede (A) versus valores reais de cobre (T).

4. Treinamento excluindo do conjunto de dados as variáveis geotécnicas: frequência de fraturas e RQD. Estas variáveis não apresentaram na análise estatística correlação linear com as concentrações metálicas. Este treinamento foi realizado com todas as variáveis geológicas e parâmetros de rede usados nos treinamentos do grupo “2”. Os resultados da rede com 30 neurônios ocultos são exibidos na figura 5.23 onde o erro de treinamento é

igual a 6,3% e o coeficiente de correlação das saídas com os valores reais de cobre é 0,695.

Novamente a rede não sofreu alteração expressiva no desempenho do treinamento devido a exclusão de variáveis com baixa correlação com a mineralização.

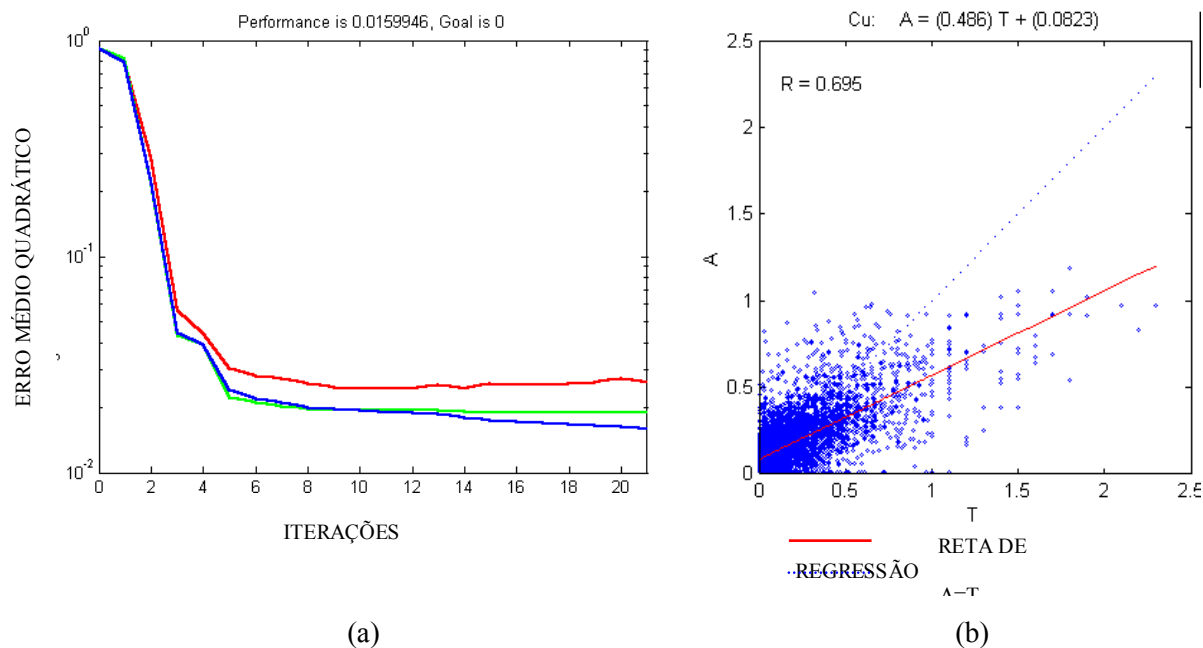


Figura 5.23 - (a) Curva de treinamento sem variáveis geotécnicas (azul: treinamento; verde: validação; vermelho: teste); (b) gráfico de dispersão das saídas da rede (A) versus valores reais de cobre (T).

O teste de generalização com o subconjunto de teste, representando 5% do conjunto total de dados piloto, foi realizado nas redes que apresentaram o melhor desempenho no processo de treinamento: as redes com 30 neurônios ocultos das grupos “2” e “4”. A matriz com 21 variáveis geológicas e geotécnicas por 313 registros foi introduzida nas redes neurais e processadas. As saídas das redes foram comparadas com os valores da matriz de 2 x 313 contendo as variáveis de concentração metálica (teores de ouro e cobre). Os gráficos de comparação apresentados na figura 5.24 indicam coeficientes de correlação muito próximos alcançados por ambas as redes justificando a adoção da configuração mais simples, isto é, a rede alimentada somente com variáveis geológicas, como a solução a ser otimizada.

Os coeficientes de correlação do subconjunto de teste mantiveram-se no mesmos níveis obtidos no subconjunto de treinamento, mostrando que as redes desempenham tão bem na generalização quanto no treinamento. Isto também evidencia a adequação do número de dados dos subconjuntos utilizados.

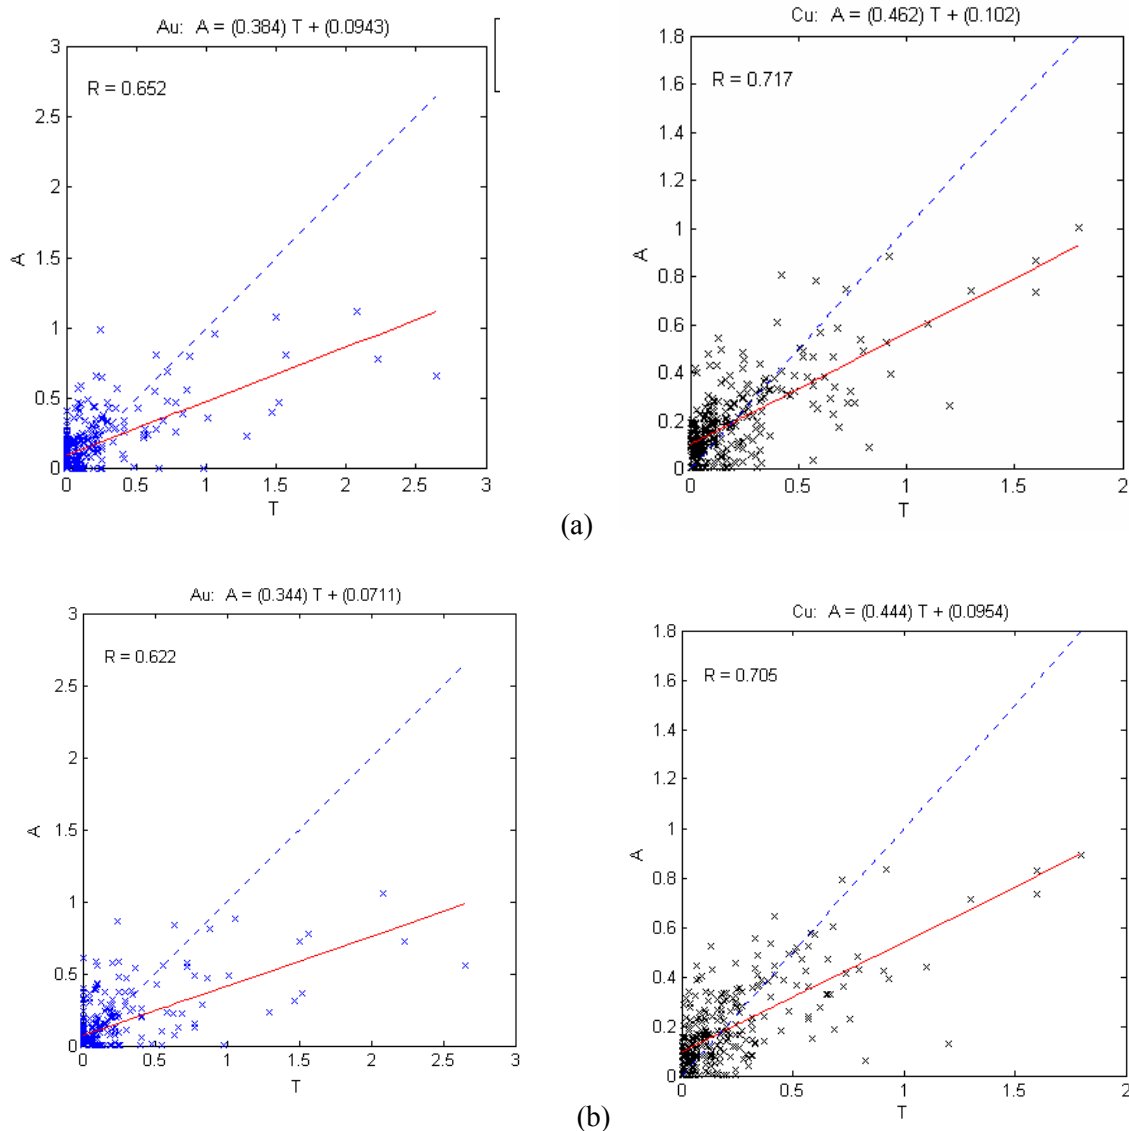


Figura 5.24 - Teste de generalização nos grupos “2” (a) e “4” (b) expresso no gráficos de dispersão de saídas das redes (A) *versus* teores de cobre e ouro (T).

Um defeito persistente desde o treinamento é a dificuldade das redes em lidar com valores elevados, isto é, tende a subestimar os teores altos de cobre e ouro. Este achatamento pode ter origem nas funções de ativação ou na arquitetura da rede.

A estabilização do erro alcançada pela soluções aplicadas no bloco piloto indicam potencial para uso de soluções mais complexas, as quais foram implementadas na etapa de otimização cujos resultados serão apresentados a seguir.

### 5.6.2 Otimização e aplicação extensiva

A capacidade preditiva das redes neurais para mineralização de cobre, que é o principal produto econômico do depósito, traduz-se no coeficiente de correlação em torno de 0,70 obtido pelas configurações com melhor desempenho no bloco piloto. O processo de otimização buscou melhorar este desempenho preditivo reduzindo a margem de erro ao máximo de 20%, que seria um limite de tolerância aceitável para a aplicação da técnica na indústria mineral.

A configuração de rede selecionada como ponto de partida para o processo de otimização abriga 33 neurônios na camada oculta e 2 neurônios na camada de saída, com funções de ativação tangente sigmoide e linear saturada, respectivamente. Na primeira etapa de otimização a rede foi alimentada com 19 variáveis geológicas acrescidas de 3 coordenadas espaciais das amostras de sondagem: leste (“X”), norte (“Y”) e elevação acima do nível do mar (“Z”). A tabela 5.12 sumariza os resultados das sessões de treinamento individualizadas utilizando algoritmo Levenberg-Marquardt (LM) nos subconjuntos de dados dos blocos “1” a “4”. Os pesos sinápticos foram zerados antes do início de cada sessão. Os detalhes de cada sessão podem ser graficamente visualizados nas figuras 5.25 a 5.28 .

Tabela 5.12 - Resultados do treinamento de redes neurais com variáveis geológicas e coordenadas espaciais utilizando algoritmo Levenberg-Marquardt.

	Bloco 1	Bloco 2	Bloco 3	Bloco 4
Erro (%) (treinamento)	4,6	5,0	3,8	3,8
Correlação Au	0,808	0,631	0,513	0,730
Correlação Cu	0,844	0,792	0,850	0,809

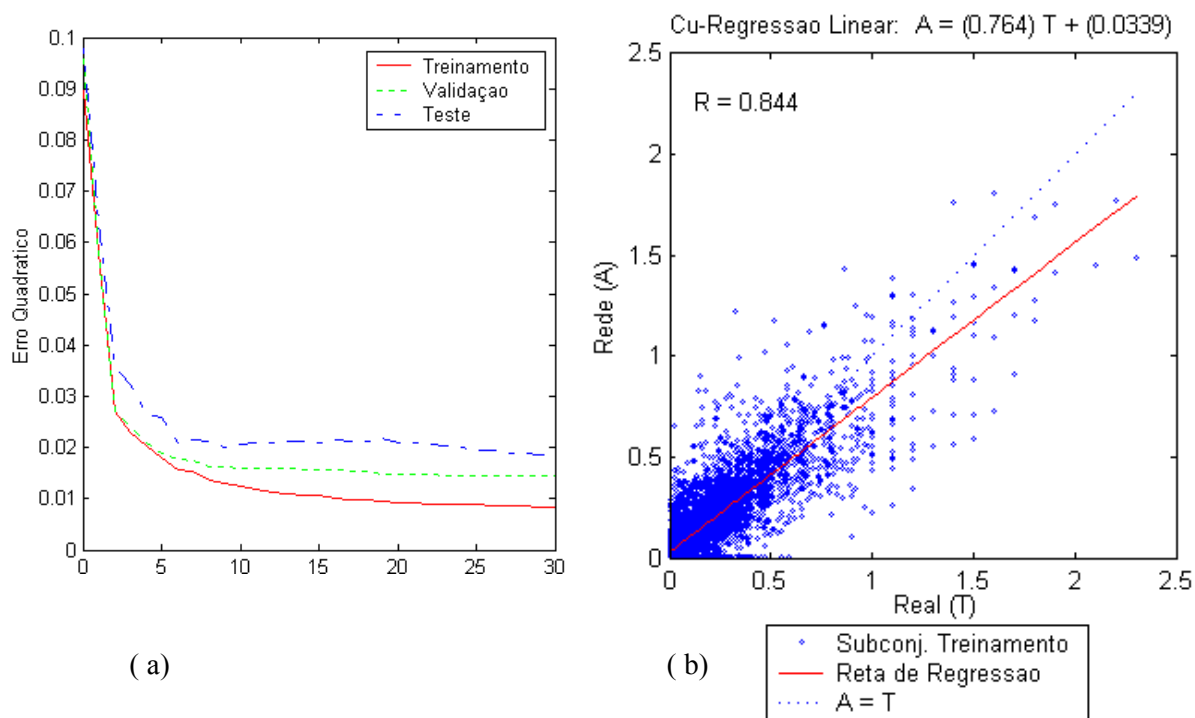


Figura 5.25 – Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 1.




Figura 5.26 – Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 2.

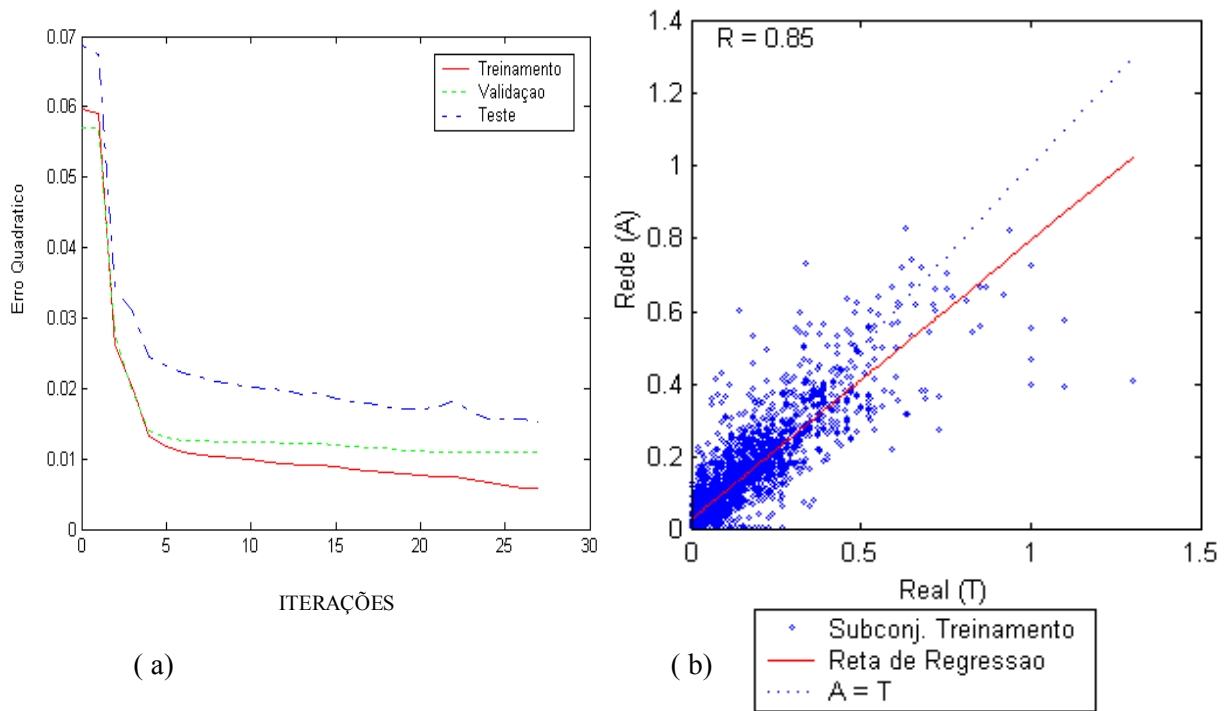


Figura 5.27 – Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 3.

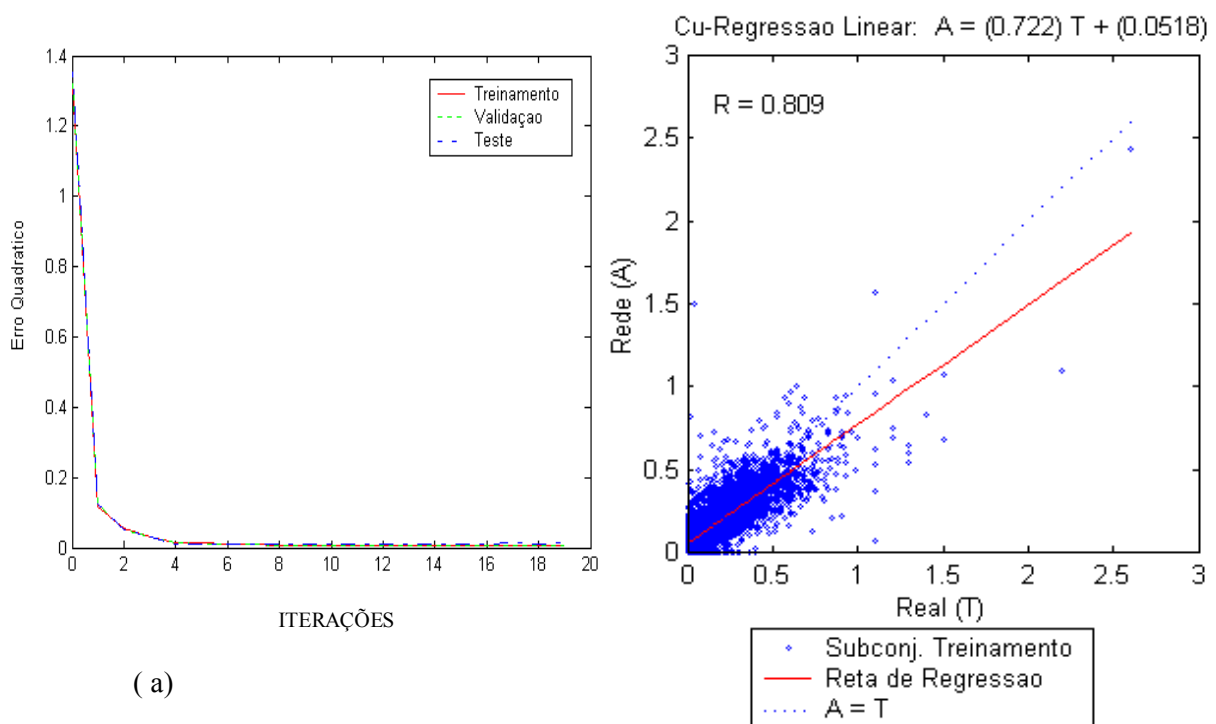


Figura 5.28 – Curva de treinamento (a) e gráfico de dispersão das saídas da rede versus valores reais de cobre (b) do bloco 4.

A introdução das variáveis espaciais melhorou significativamente o coeficiente de correlação entre as saídas da rede e os valores reais de ouro e cobre obtidos no treinamento, chegando a ultrapassar o valor de 0,80 para o cobre. Cabe esclarecer entretanto que este coeficiente está fortemente influenciado pelos subconjuntos de treinamento e validação expressando mais o sucesso da aprendizagem que a capacidade de generalização da rede, isto é, a rede “memorizou” bem o posicionamento das amostras e os respectivas concentrações metálicas. Quando alimentada somente com o subconjunto de dados “teste” que não participou do processo de treinamento, a real habilidade de predição da rede pode ser aferida. Os resultados exibidos nos gráficos da figura 5.29 e compilados na tabela 5.13 apontam coeficientes de correlação em sua maioria mais modestos que os obtidos no treinamento, porém ainda superiores àqueles alcançados no teste de generalização do conjunto piloto (figura 5.23), comprovando o benefício da introdução das variáveis espaciais. Confirmando a tendência revelada no treinamento, a simulação da rede obteve as melhores respostas nos blocos 1 e 2.

Tabela 5.13 - Resultados do teste de generalização de redes neurais com variáveis geológicas e coordenadas espaciais utilizando algoritmo Levenberg-Marquardt.

	Bloco 1	Bloco 2	Bloco 3	Bloco 4
Correlação Au	0,689	0,691	0,611	0,649
Correlação Cu	0,787	0,744	0,711	0,678

A etapa seguinte do processo de otimização visou melhorar a capacidade de generalização da rede configurada na etapa anterior aplicando a regularização bayesiana em combinação com o algoritmo de treinamento Levenberg-Marquardt. A tabela 5.14 sumariza os resultados das sessões individuais de treinamento com regularização bayesiana para os quatro blocos do depósito.

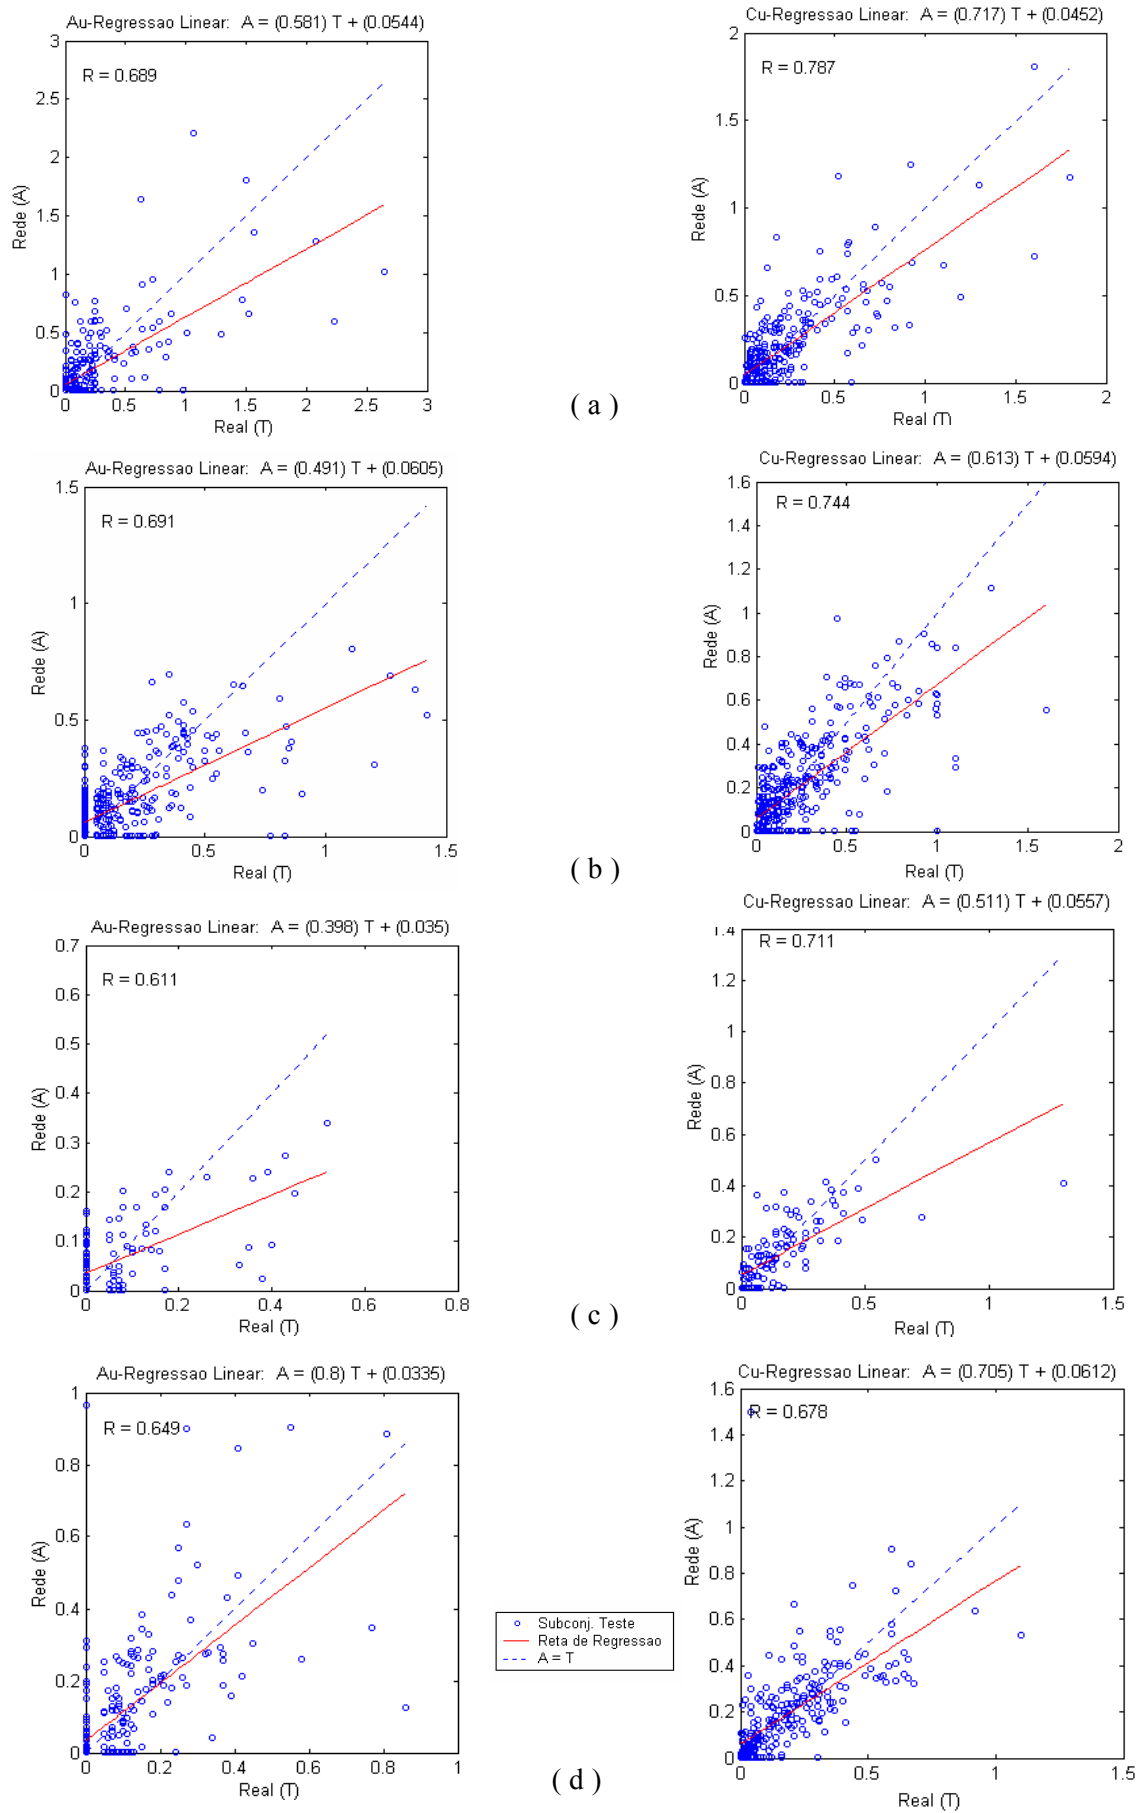


Figura 5.29 – Teste de generalização de redes treinadas com algoritmo Levenberg-Marquardt. Gráficos de dispersão dos teores de ouro (esq.) e cobre (dir.) nos blocos 1 (a), 2 (b), 3 (c) e 4 (d).

Tabela 5.14 - Resultados do treinamento de redes neurais com algoritmo Levenberg-Marquardt e regularização bayesiana.

	Bloco 1	Bloco 2	Bloco 3	Bloco 4
Erro (%)	4,3	4,4	2,1	3,2
Correlação Au	0,829	0,708	0,569	0,773
Correlação Cu	0,856	0,855	0,891	0,823

Comparando os coeficientes de correlação da tabelas 5.12 e 5.14 observa-se nesta última um ganho de desempenho de 2,5 % a 12 % para os teores de ouro e de 1,4% a 8 % para os teores de cobre. A exemplo anterior a aferição desse ganho como real melhoria da capacidade preditiva da rede foi possível com o teste de generalização aplicado no subconjunto “teste”, cujos resultados encontram-se compilados na tabela 5.15 e graficamente apresentados na figura 5.30.

Tabela 5.15 - Resultados do teste de generalização de redes neurais com algoritmo Levenberg-Marquardt e regularização bayesiana.

	Bloco 1	Bloco 2	Bloco 3	Bloco 4
Correlação Au	0,763	0,684	0,527	0,680
Correlação Cu	0,828	0,779	0,727	0,762

A comparação entre os resultados do teste de generalização da rede treinada com algoritmo Levenberg-Marquardt associado a regularização bayesiana (tabela 5.15) e aquele realizado sem regularização (tabela 5.13) permite as seguintes constatações:

- Para os teores de ouro a regularização trouxe ganhos preditivos aos blocos “1” (10,7%) e “4” (4,8 %) e perdas de desempenho aos blocos “2”(-1 %) e “3”(-13,7%);
- A regularização promoveu uma melhoria entre 2,3 % a 12,4 % na capacidade de predição dos teores de cobre para todos os blocos.

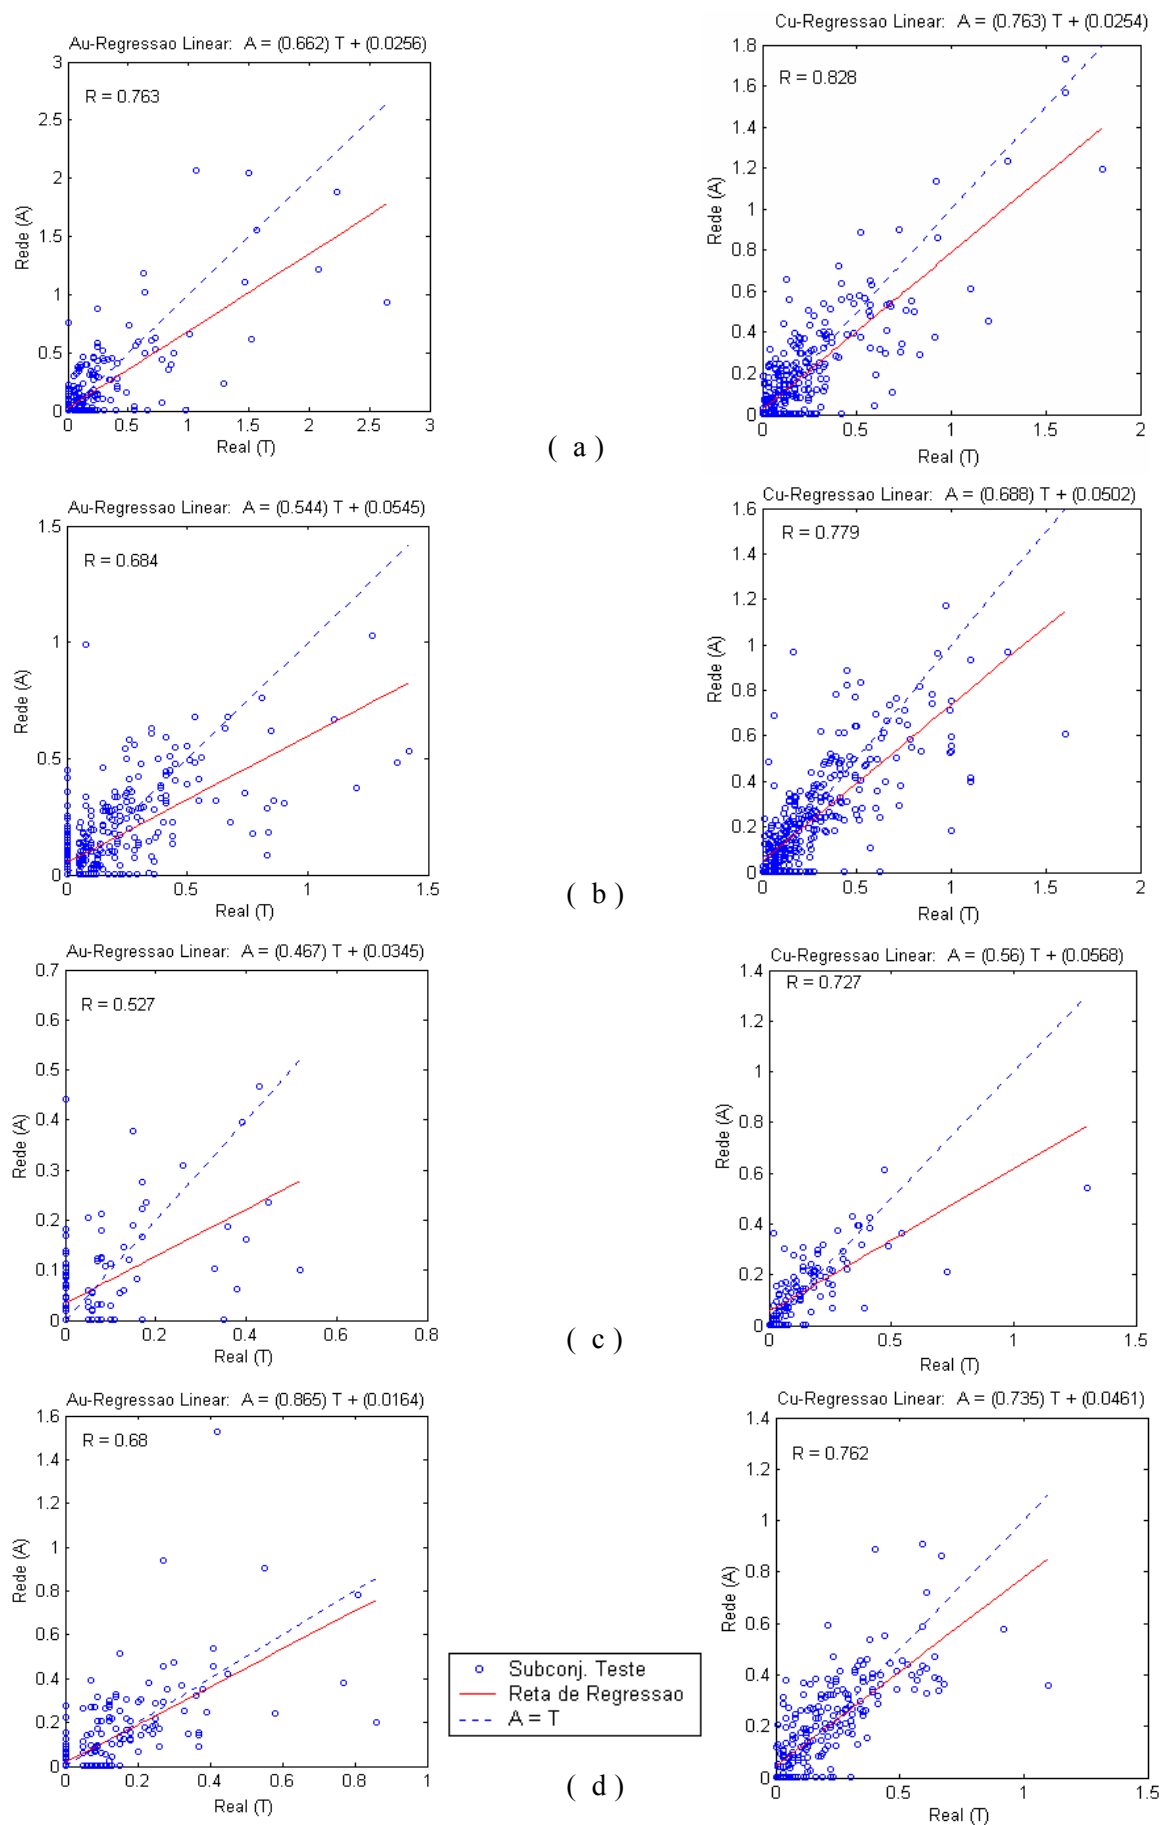


Figura 5.30 – Teste de generalização de redes treinadas com algoritmo Levenberg-Marquardt e regularização bayesiana. Gráficos de dispersão dos teores de ouro (esq.) e cobre (dir.) nos blocos 1 (a), 2 (b), 3 (c) e 4 (d).

A significativa perda de desempenho preditivo para teores de ouro no bloco “3” está relacionada ao número de dados reduzido (2.473), menos que a metade dos demais blocos, com distribuição espacial irregular. Isto se reflete também na degeneração acentuada do coeficiente de correlação dos teores de cobre obtidos no treinamento (tabela 5.14) para aqueles obtidos na generalização (tabela 5.15), igual a  $-18,4\%$ .

O melhor resultado do processo de otimização foi alcançado pelo conjunto de dados piloto (bloco “1”) onde o coeficiente de correlação para cobre se manteve acima de 0,80 em ambas as sessões de treinamento e generalização, com uma variação de desempenho entre uma e outra de apenas  $-3,3\%$ . Esta “estabilização” traduz a importância de uma distribuição espacial de dados regular aliada a um número satisfatório de registros para o desempenho preditivo robusto da rede neural. É importante ressaltar entretanto, que a regularidade diz respeito à distribuição espacial e não às estimativas das variáveis, uma vez que a homogeneidade dos conjuntos é deletéria para o desempenho das redes neurais, embora a heterogeneidade extrema também o seja, isto é, há que se buscar o contraste ideal.

### 5.6.3 Aplicação em seções de sondagem

Para o teste final de generalização e aplicação prática das redes neurais otimizadas foram selecionadas uma seção de sondagem de cada bloco de dados, a saber: seção 1100 do bloco “1”, seção 2250 do bloco “2”, seção 3100 do bloco “3” e seção 3800 do bloco “4”. As redes anteriormente treinadas em cada bloco foram alimentadas somente com dados das seções selecionadas em um processo chamado simulação e as saídas das redes foram comparadas com os valores reais dos teores de ouro e cobre (figura 5.31). A tabela 5.16 apresenta os coeficientes de correlação obtidos na simulação.

Tabela 5.16- Resultados da simulação de redes neurais nas seções de sondagem.

	1100 (Bloco 1)	2250 (Bloco 2)	3100 (Bloco 3)	3800 (Bloco 4)
Correlação Au	0,767	0,756	0,737	0,841
Correlação Cu	0,807	0,853	0,878	0,833
Variáveis x Amostras	22 x 648	22 x 716	21 x 369	21 x 344

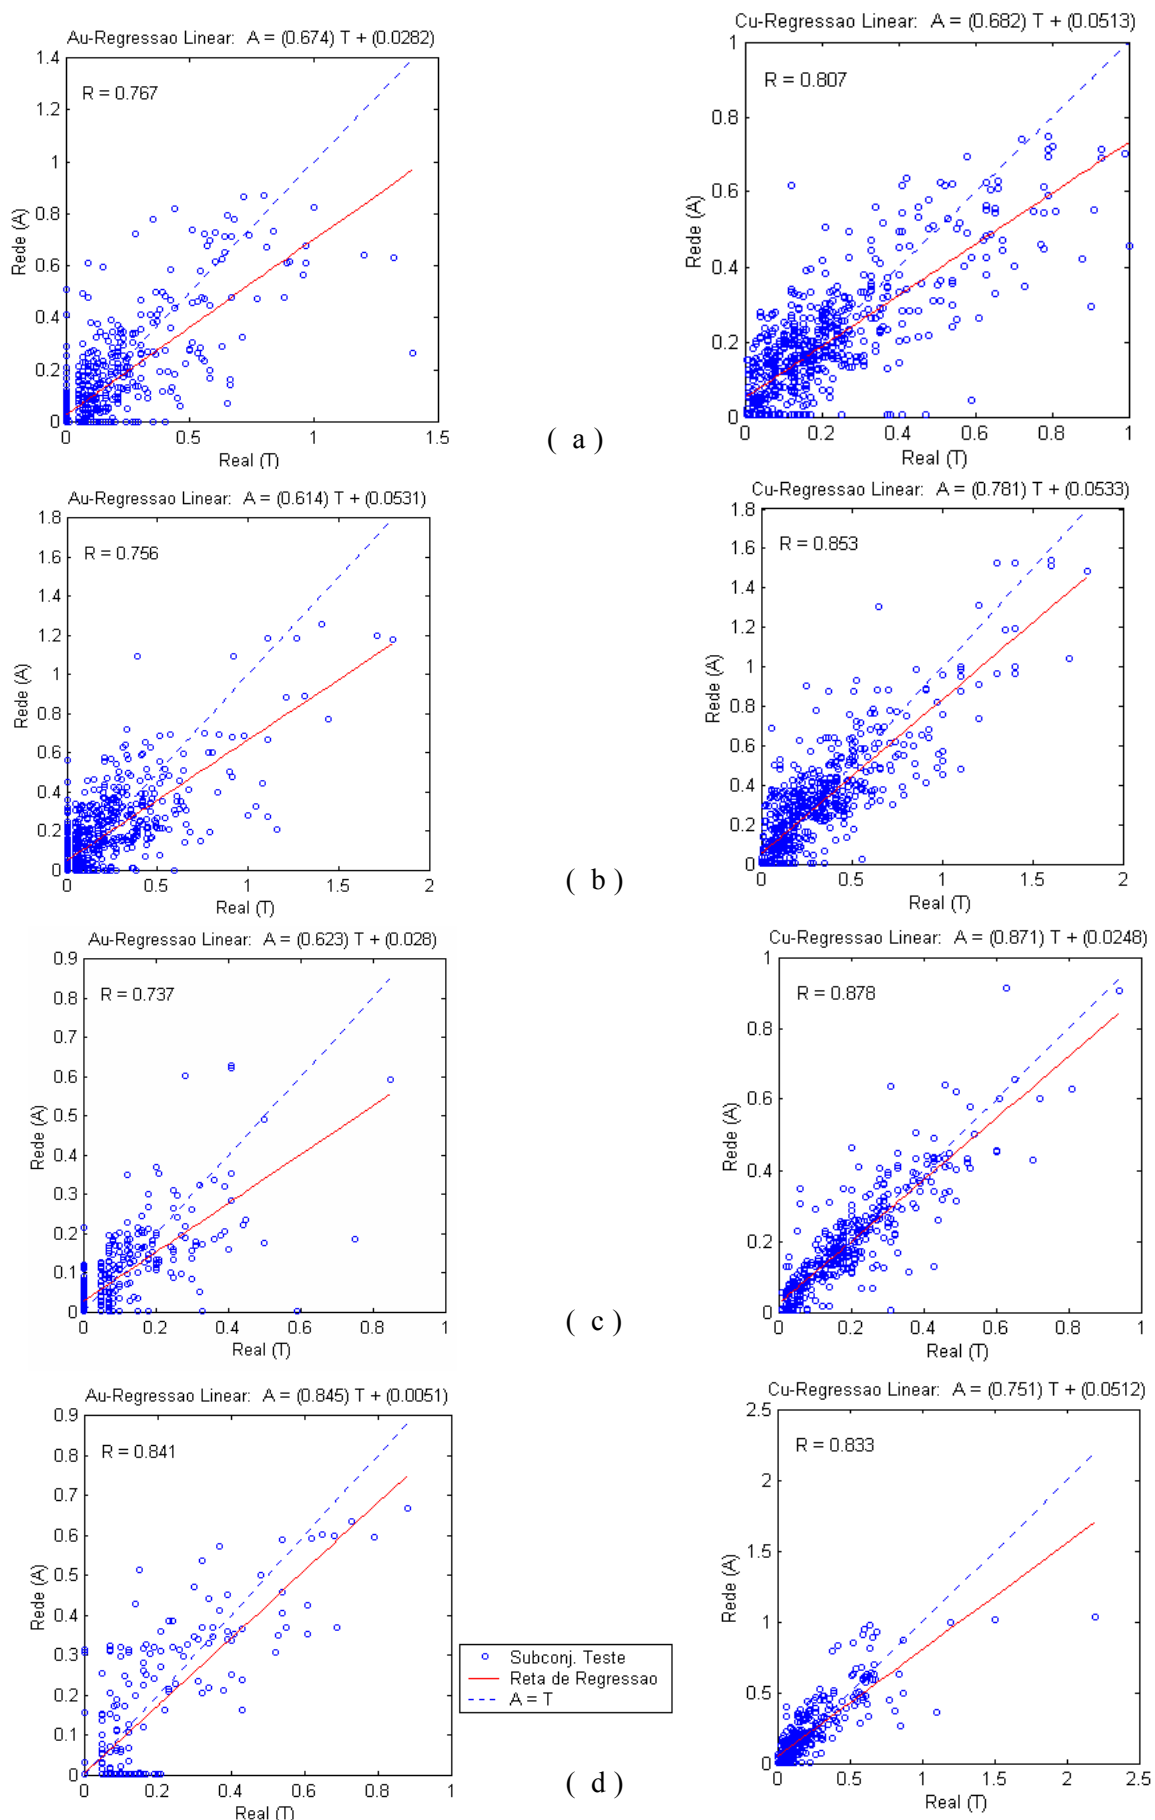


Figura 5.31 – Teste final de generalização de redes neurais. Gráficos de dispersão dos teores de ouro (esq.) e cobre (dir.) nas seções de sondagem 1100 (a), 2250 (b), 3100 (c) e 3800 (d).

Visando o teste prático da aplicação proposta, os valores reais de cobre e aqueles resultantes das saídas das redes neurais, oriundos de intervalos de sondagem com 1,40 m, foram compostos em intervalos de 10 m, simulando a altura das futuras bancadas de lavra. As seções de sondagem contidas no APÊNDICE A apresentam o comparativo entre os compósitos da variável teor de cobre ('REAL') e saída da rede neural ('REDE\_NEURAL'). Considerando as classes de teores definidas pela Mineração Maracá para a operação de lavra do depósito de Chapada, o grau de acerto das respostas da rede neural variou de 80% (seção 2250) a 90% (seções 3100 e 3800) (tabela 5.17). Atenção especial deve ser dispensada à classificação entre o minério de baixo teor e o material estéril, definida pelo teor de corte de 0,285%. A destinação de minério para a pilha de estéril e vice-versa é um erro irrecuperável e gera prejuízo econômico, portanto, sugere-se a adoção de uma margem de erro de +-20% no teor de corte, dentro da qual a classificação exigiria elementos adicionais.

Tabela 5.17- Resultados do desempenho das redes neurais simulando bancadas de 10 m.

	1100 (Bloco 1)	2250 (Bloco 2)	3100 (Bloco 3)	3800 (Bloco 4)
Número de compósitos (10 m)	110	100	43	55
Índice de acertos	86%	80%	90%	90%
Erros na classificação estéril / minério	6%	13%	7%	4%

#### 5.6.4 Avaliação da redução de variáveis na rede neural otimizada

Objetivando identificar as variáveis de entrada mais influentes na eficiência da rede neural em prever os teores de ouro e cobre nas futuras bancadas de lavra, selecionou-se como objeto de estudo a rede otimizada do bloco "1" (área piloto), por ter apresentado o melhor desempenho preditivo entre todas as outras.

A importância relativa de cada variável no desempenho da rede neural pode ser inicialmente avaliada pela análise da matriz de pesos sinápticos das conexões entre a camada de entrada e a camada oculta, na qual os maiores pesos em valores absolutos estão relacionados às

variáveis mais influentes. A tabela 5.18 apresenta a matriz de pesos da rede neural treinada com algoritmo Levenberg-Marquardt e regularização bayesiana, com as 22 variáveis de entrada ordenadas em ordem decrescente segundo o somatório absoluto dos respectivos pesos. Essa mesma ordenação pode ser visualizada no gráfico de barras da figura 5.32 onde destaca-se um grupo inicial de oito variáveis com maior peso, seguido de um grupo intermediário de sete variáveis com peso menor e por último sete variáveis com peso mínimo. Entre as variáveis de maior destaque estão aquelas relacionadas diretamente à mineralização (“porcentagem de sulfetos” e “razão calcopirita/pirita”), as variáveis espaciais “X” e “Z” e a variáveis “biotita-cianita-xisto” e “anfibiólio-xisto”, representativas do dois principais grupos litológicos do depósito. É interessante notar o comportamento polarizado desses pares de variáveis principais, exemplificado pelas variáveis litológicas, quando a presença de “biotita-cianita-xisto” eleva os teores e a ocorrência de “anfibiólio-xisto” produz o efeito contrário.




Figura 5.32 – Gráfico de barras mostrando as variáveis de entrada em ordem decrescente segundo os pesos sinápticos de entrada da rede neural.

O passo seguinte consistiu em testar o desempenho da rede neural face à redução gradativa das variáveis de entrada, seguindo o ordenamento observado na matriz de pesos sinápticos. As variáveis foram extraídas uma a uma na direção crescente do gráfico da figura 5.32, e a cada extração aplicou-se o teste de generalização. As saídas da rede neural para cada simulação foram

Tabela 5.18 – Matriz de pesos sinápticos entre a camada de entrada e camada oculta da rede neural otimizada do bloco “1”.

VARIÁVEIS																													ABS(Σ)					
Biot-cianita-xisto	0.266	0.857	0.167	0.481	0.101	0.082	0.007	(0.805)	0.490	(0.818)	0.533	0.438	(0.228)	0.339	0.836	0.571	0.862	0.439	0.110	(0.077)	0.499	0.018	0.027	0.026	(0.443)	0.207	1.020	0.133	(0.461)	(0.225)	(0.135)	(0.061)	(0.061)	5.210
X	(0.384)	0.317	0.098	(0.463)	0.064	(0.294)	0.087	(0.433)	(0.334)	1.208	0.303	0.153	0.247	(0.424)	1.893	(0.427)	0.546	0.146	0.043	(0.052)	(0.114)	(0.340)	0.342	(0.288)	(0.291)	0.661	1.417	(0.126)	(0.690)	1.759	(0.103)	0.188	0.430	5.137
CP_PY	(2.326)	(0.626)	(0.004)	0.555	(0.263)	(0.365)	(0.983)	1.499	(0.396)	(0.281)	(0.285)	(0.932)	(0.529)	(0.985)	0.488	0.095	(0.534)	0.135	(0.783)	0.198	(0.076)	0.200	(0.084)	0.648	(0.848)	0.802	1.212	1.543	(0.511)	0.581	0.378	(1.736)	(0.050)	4.262
SULPCT	(1.227)	0.429	1.522	(0.150)	0.386	0.561	(0.577)	0.723	(0.999)	(0.376)	(0.702)	0.852	(0.490)	(0.225)	(0.481)	0.755	(0.061)	(0.137)	(0.589)	(1.839)	1.555	0.229	0.872	(0.392)	(0.143)	0.646	0.763	0.885	(0.464)	0.281	0.688	0.908	0.439	3.646
Z	0.004	0.097	(0.315)	(0.661)	(0.027)	(1.839)	(0.183)	0.361	(0.682)	0.884	(0.529)	0.135	0.697	0.058	(0.711)	(0.342)	0.084	0.594	(0.250)	(0.309)	(0.477)	(1.104)	0.406	(0.137)	0.600	0.619	0.504	(0.225)	(2.207)	0.781	(0.027)	0.607	0.289	3.304
Anf-xisto	(0.285)	0.062	0.068	(0.922)	0.289	(0.286)	0.444	(0.155)	(0.667)	0.456	0.185	0.151	(0.048)	(0.411)	(0.063)	(0.295)	0.208	(0.124)	0.284	(0.092)	0.388	0.255	0.300	(0.202)	(0.072)	(0.445)	(0.471)	(0.776)	0.092	(0.028)	0.080	(0.139)	(0.391)	2.610
EPIDOT	0.261	0.127	(0.207)	(0.291)	(0.114)	0.281	0.029	(0.209)	0.704	0.575	0.235	0.975	(0.009)	0.035	(1.106)	(0.229)	0.595	(1.408)	0.302	(0.193)	(0.094)	0.402	(0.437)	(0.353)	(0.154)	(0.039)	(0.308)	(0.484)	(0.306)	(0.039)	(0.597)	(0.124)	(0.177)	2.355
SILICI	(0.564)	(0.234)	0.523	(0.218)	0.121	0.209	(0.228)	0.368	(0.346)	0.186	(0.331)	(0.728)	0.156	0.119	0.395	(0.166)	(0.105)	(0.013)	(0.295)	(0.270)	0.100	(0.191)	(0.333)	0.283	0.138	(0.138)	0.088	0.368	(0.094)	0.253	(0.165)	(0.229)	(0.016)	1.355
Pegmatito	0.073	0.149	(0.356)	(0.058)	(0.263)	(0.158)	0.081	0.424	(0.067)	0.151	(0.066)	(0.051)	(0.452)	0.700	0.454	(0.052)	(0.289)	0.396	0.316	0.075	(0.009)	(0.137)	(0.015)	0.023	0.133	(0.041)	(0.126)	0.208	(0.032)	(0.196)	0.131	(0.200)	0.202	0.946
Anfibolito	(0.085)	0.252	(0.281)	0.055	(0.217)	(0.039)	0.284	0.023	0.072	0.022	0.145	(0.091)	(0.053)	(0.020)	0.260	(0.010)	0.080	0.298	0.233	0.043	0.102	(0.211)	0.114	0.013	0.118	(0.099)	0.058	0.021	(0.231)	(0.053)	0.024	0.001	0.033	0.860
Antofilita-xisto	0.079	0.319	(0.096)	0.752	(0.324)	(0.268)	(0.145)	(0.290)	0.017	(0.073)	(0.082)	(0.652)	0.049	0.103	(0.183)	0.055	0.301	0.348	(0.442)	0.041	0.393	(0.275)	(0.075)	0.428	(0.002)	0.070	(0.107)	0.065	(0.370)	0.021	(0.213)	0.032	(0.310)	0.835
Microgranod.	0.062	0.259	(0.221)	0.073	(0.185)	(0.064)	0.166	(0.144)	0.105	0.021	0.194	(0.152)	0.003	0.017	0.253	(0.010)	0.093	0.298	0.128	0.047	0.084	(0.216)	0.115	0.068	0.034	(0.025)	(0.015)	0.015	(0.226)	(0.095)	0.037	(0.124)	0.026	0.623
Anfibolito-band	0.062	0.259	(0.222)	0.073	(0.184)	(0.064)	0.166	(0.144)	0.105	0.021	0.195	(0.152)	0.002	0.017	0.253	(0.010)	0.093	0.298	0.128	0.047	0.083	(0.216)	0.115	0.067	0.035	(0.026)	(0.013)	0.015	(0.227)	(0.095)	0.037	(0.124)	0.026	0.620
Solo	0.130	0.005	(0.473)	(0.326)	(0.282)	0.819	(0.117)	(0.368)	0.311	0.126	0.300	(0.254)	0.173	(0.236)	0.126	0.094	(0.299)	0.420	0.020	0.088	0.075	(0.089)	(0.065)	0.023	0.246	0.171	(0.045)	0.013	(0.398)	(0.264)	0.531	(0.096)	0.184	0.542
CARBON	0.253	(0.473)	(0.367)	0.061	(0.329)	0.059	0.910	(0.282)	0.246	(0.288)	(0.427)	0.097	(0.060)	(0.137)	(0.333)	0.315	(0.188)	1.112	0.764	0.594	(0.245)	(1.220)	0.242	(0.246)	0.036	(0.229)	(0.191)	0.072	0.234	(0.233)	0.272	0.141	0.338	0.497
PYRIT	(0.042)	(0.141)	0.437	(1.034)	1.541	0.033	(1.240)	0.993	0.278	0.830	0.341	0.358	0.462	(0.372)	(0.110)	(1.054)	(1.025)	0.073	(1.287)	(0.292)	(0.316)	(0.026)	0.091	(0.267)	0.192	(0.040)	0.047	(0.358)	0.136	0.755	0.141	(0.138)	0.747	0.287
Biot-qtzo-xisto	0.381	0.390	(0.124)	0.259	0.027	(0.294)	0.175	(0.226)	0.281	(0.178)	0.006	(0.274)	0.309	(0.302)	(0.030)	(0.008)	(0.042)	0.090	0.004	0.541	(0.062)	(0.871)	0.475	(0.084)	(0.181)	0.096	0.070	0.029	(0.020)	(0.018)	(0.232)	(0.171)	0.243	0.259
CHLORI	0.318	0.323	(0.495)	(0.224)	(0.181)	(0.015)	0.177	(0.580)	(0.201)	(0.074)	(0.245)	0.206	0.375	0.233	0.002	0.353	0.032	(0.284)	(0.130)	(0.038)	(0.507)	0.343	0.471	(0.277)	0.268	0.102	(0.016)	0.000	0.078	(0.062)	(0.079)	0.468	(0.583)	0.243
Y	0.436	(0.270)	0.032	0.794	(0.005)	(1.449)	(0.969)	0.565	(0.490)	0.192	0.002	(0.086)	(0.201)	(0.233)	0.192	(0.699)	(0.334)	0.281	(0.883)	0.279	(0.426)	(0.049)	0.776	0.417	(0.091)	0.226	0.523	0.088	0.695	0.539	0.411	0.453	(0.496)	0.219
Metatufa	0.138	0.045	(0.115)	(0.061)	(0.295)	(0.008)	0.177	0.002	0.202	0.060	0.217	(0.346)	(0.128)	(0.013)	0.091	(0.251)	(0.180)	0.246	0.097	(0.128)	(0.328)	(0.224)	0.046	0.155	0.017	(0.097)	(0.187)	0.434	(0.079)	0.096	0.082	0.179	0.008	0.149
SERICI	(0.205)	0.185	(0.063)	(0.234)	0.362	0.411	(0.350)	(0.142)	0.110	(0.669)	(0.963)	0.743	0.277	0.133	(0.152)	1.574	(0.555)	0.066	(0.480)	0.350	(0.290)	0.023	0.033	(0.554)	0.265	(0.097)	(0.038)	1.306	(0.217)	(0.166)	0.140	(0.200)	(0.485)	0.116
Biot-xisto	(0.281)	(0.266)	(0.345)	0.333	(0.323)	(0.296)	0.255	0.386	0.094	0.400	0.125	0.011	0.390	(0.037)	0.278	(0.176)	0.012	(0.030)	0.275	(0.164)	(0.474)	0.022	(0.001)	0.085	0.433	(0.044)	(0.304)	(0.019)	(0.088)	0.006	(0.005)	(0.413)	0.273	0.110

comparadas com os valores reais em gráficos de dispersão, cujos coeficientes de correlação linear encontram-se representados graficamente na figura 5.33. A degeneração da capacidade preditiva da rede é lenta e discreta, caindo abaixo de 80% de acerto para os teores de cobre após a exclusão de 5 variáveis, e abaixo de 70% somente após a exclusão de 19 variáveis.




Figura 5.33 – Gráfico cumulativo do desempenho preditivo da rede neural em função das variáveis de entrada utilizadas na simulação.

Considerando a possibilidade do resultado do teste de generalização incremental estar influenciado por interações complexas de variáveis, repetiu-se o teste extraindo as variáveis que se mostraram visivelmente redundantes no gráfico da figura 5.33. Das 22 variáveis de entrada foram descartadas 12, restando para simulação: as variáveis espaciais (“X”, “Y”, “Z”); as variáveis de mineralização (“porcentagem de sulfetos” e “razão calcopirita/pirita”); as litologias biotita xisto, biotita-cianita xisto e anfibólio xisto e as alterações hidrotermais piritização e cloritização. Obteve-se nesta simulação coeficientes de correlação de 0,75 para teores de ouro e de 0,82 para teores de cobre (figura 5.34), confirmando a manutenção da capacidade de generalização da rede neural para as dez variáveis selecionadas em nível muito próximo ao desempenho preditivo de base (0,76 para ouro e 0,83 para cobre).

Finalmente a rede foi testada somente com as primeiras cinco variáveis da matriz de pesos sinápticos: a litologia biotita-cianita xisto, as variáveis espaciais “X” e “Z” e as variáveis de mineralização. Os resultados da simulação mostrados no gráfico de dispersão da figura 5.35 expressam-se nos coeficientes de correlação de 0,70 para teores de ouro e de 0,79 para teores de

cobre. Embora possam ser ainda considerados satisfatórios, esses resultados representam uma degradação da capacidade preditiva da rede neural comparativamente ao teste anterior.

Os testes de redução de variáveis evidenciaram aquelas mais importantes para o bom desempenho da rede neural, no entanto cabe ressaltar a limitação espacial dos testes realizados, não havendo garantia de reprodução dos resultados em outras áreas do depósito.




Figura 5.34 – Teste de generalização da rede neural do bloco “1” com 10 variáveis de entrada. Gráficos de dispersão dos teores de ouro (esq.) e cobre (dir.).

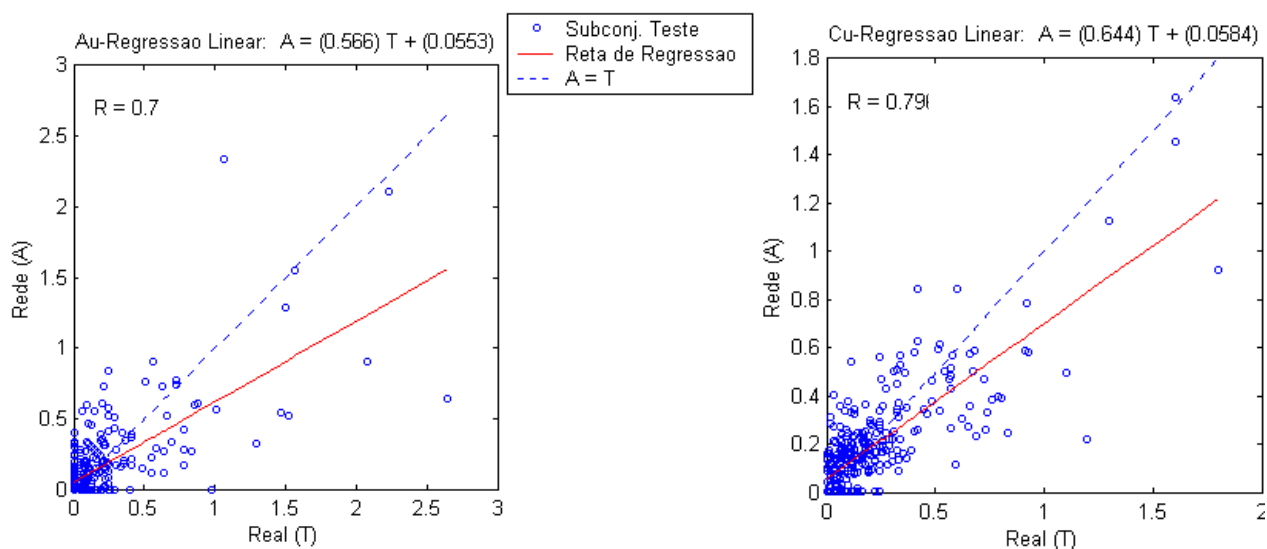


Figura 5.35 – Teste de generalização da rede neural do bloco “1” com 5 variáveis de entrada. Gráficos de dispersão dos teores de ouro (esq.) e cobre (dir.).

## CAPÍTULO 6. CONCLUSÕES E SUGESTÕES

---

Neste trabalho foi demonstrada a viabilidade da aplicação da técnica de redes neurais artificiais na estimativa de teores de minério a partir de observações geológicas e geotécnicas quantificadas.

O conjunto de dados utilizados nesta modelagem foi extraído da base de dados de sondagem do depósito de cobre e ouro de Chapada (GO), pertencentes a Mineração Maracá S.A. Compõe-se de variáveis geológicas como litologia, tipo e intensidade de alterações hidrotermais, tipo e frequência de minerais de minério, variáveis geotécnicas tais como frequência de fraturas e RQD e as variáveis de concentração metálica (teores de cobre e ouro) alvos deste trabalho. Durante os trabalhos de pesquisa mineral do depósito o relacionamento das variáveis geológicas e geotécnicas com a mineralização foi analisado qualitativamente, e algumas conclusões são baseadas em critérios subjetivos. A análise estatística das variáveis revelou entretanto, ligações lineares frágeis e até inexistentes, com exceção do relacionamento óbvio entre teores e minerais de minério. A técnica de redes neurais é capaz entretanto, de mapear relações não-lineares multivariadas com intensidades distintas. Por este motivo, embora comumente vantajosa, a redução de variáveis aumenta o risco das redes neurais perderem algumas complexas interações dessas variáveis. No presente estudo, o desempenho preditivo de base das redes neurais foi medido inicialmente com todas as variáveis.

A análise geoestatística dos teores de cobre e ouro, evidenciou claramente a concentração da mineralização na zona apical do corpo principal, apresentando maior continuidade ao longo do eixo da antiforma. As amplitudes variográficas dos teores de cobre e ouro confirmam ainda a propriedade da malha de amostragem adotada, autorizando até a adoção de espaçamento maior nas amostragens futuras.

O modelo de rede neural utilizado foi o de múltiplas camadas (MLP) alimentada adiante (“feedforward”) totalmente interconectada e com apenas uma camada oculta de neurônios. Esta rede foi treinada com o algoritmo de Levenberg-Margquardt, baseado no conceito de retropropagação do erro, e validação cruzada simultânea ao treinamento através do *método da parada antecipada* (“early stopping”). Variando alguns parâmetros da rede como número de neurônios ocultos, função de ativação e número de nós de fonte (variáveis

de entrada) o desempenho das redes foi comparado e avaliado. O melhor desempenho foi obtido pela rede com 30 neurônios ocultos, utilizando todas as variáveis de entrada e funções de ativação tangente hiperbólica na camada oculta e linear saturada na camada de saída. O erro médio de treinamento da rede girou em torno de 6%, o que é considerado muito satisfatório. Este nível de desempenho manteve-se inalterado em termos qualitativos em todas as configurações testadas comprovando a robustez e capacidade de adaptação da técnica. O coeficiente de correlação linear entre os teores estimados pela rede e os respectivos valores reais foi 0,65 para ouro e 0,75 para cobre. Estes números se reproduziram no teste de generalização realizado com dados que não fizeram parte do treinamento. Os coeficientes de correlação, insatisfatórios à primeira vista, estão muito influenciados por pares de valores extremos mal ajustados, reflexo da dificuldade da rede em lidar com teores elevados com tendência à subestimativa dos mesmos. Este defeito entretanto não é deletério considerando que os teores elevados (maior que 1ppm para ouro e 1% para cobre) representam menos de 1,5% da população de teores do depósito.

A exclusão das variáveis geotécnicas trouxe um perda de 1,6% na capacidade das redes neurais de prever os teores de cobre na parte sul do depósito, o que justificou a exclusão destas variáveis na otimização da aplicação. Ao mesmo tempo, a introdução das variáveis espaciais (“X”, “Y” e “Z”) melhorou em 11% a habilidade de generalização das redes, elevando o coeficiente de correlação dos resultados de cobre para além de 0,8. A eficiência das variáveis espaciais está ligada à continuidade da mineralização, cujos alcances variográficos são muito superiores aos espaçamentos amostrais.

A capacidade preditiva das redes MLP foi novamente otimizada com a introdução da técnica de regularização bayesiana, que no caso em estudo, provocou um ganho de desempenho de 2,3% até 12% para a previsão de teores de cobre. A variação de desempenho em relação aos teores de ouro apresentou maior amplitude, atingindo valores positivos (12%) e negativos (-13,7%). A relativa instabilidade das redes neurais na previsão do comportamento da mineralização aurífera tem origem na própria distribuição da variável, cujo coeficiente de variação é duas vezes maior que o do cobre. No outro extremo, a invariância também afeta a eficiência da técnica, sendo que domínios estatísticos com baixa variabilidade, ideais para quantificação de reservas minerais, desempenham muito mal no treinamento das redes neurais.

Uma desvantagem associada às soluções de redes neurais pode ser o tempo requerido para o treinamento, que em alguns casos, levam dias de computação. Entretanto, este não é o

caso de projetos de rede semelhantes aos apresentados aqui, onde o tempo máximo de processamento, usando como entrada matrizes de 7000 por 21, foi de 100 minutos. O tempo de processamento cresce exponencialmente com o tamanho do banco de dados, chegando a atingir 48 horas no caso do conjunto de dados original de Chapada, superior a 20.000 registros. A forma encontrada aqui para contornar este problema foi subdividir o banco de dados em subconjuntos menores, que foram processados à velocidade aproximada de  $0,52n$  segundos, onde  $n$  é o número de dados.

Outro inconveniente na aplicação da técnica na rotina de uma mina é o tempo requerido para a coleta de dados, que pode ser minimizado com a redução das variáveis a serem mapeadas. Demonstrou-se na área piloto a possibilidade de obtenção de resultados satisfatórios com cinco a dez variáveis, sendo fundamentais as observações sobre os minerais de minério (porcentagem de sulfetos e razão calcopirita/pirita), as variáveis espaciais e a presença da litologia biotita-cianita xisto. Contudo, as margens de erro na predição de teores podem ser reduzidas com a ampliação do leque de observações que, se não trazem individualmente ganhos incrementais significativos, associadas, conferem robustez e eficiência na aplicação do método.

Podemos concluir que a técnica de redes neurais mostrou-se eficiente no caso em estudo, atingindo resultados superiores a 80% de acerto nas simulações de teores de cobre em futuras bancadas de lavra a céu aberto. Sugere-se a continuidade do estudo da técnica no depósito de Chapada através do aperfeiçoamento do projeto das redes e dos algoritmos de treinamento, e a retroalimentação de dados quando do início da lavra. Vislumbra-se ainda a oportunidade de estender a utilização das redes neurais em outras áreas do projeto tais como, ambiental, objetivando a previsão do potencial de geração de drenagem ácida a partir das informações geológicas, e na área de beneficiamento mineral, auxiliando na previsão da recuperação metalúrgica a partir das informações geológicas coletadas nas frentes de lavra.

Enfim, a técnica de redes neurais artificiais é útil para a solução de alguns problemas geológicos e de engenharia, como ferramenta complementar às abordagens convencionais. O que se tem visto ultimamente é o desenvolvimento crescente de sistemas híbridos, que misturam redes neurais e métodos estatísticos e geoestatísticos.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

---

ALMEIDA, F.F.M. **Observações sobre o Pré-Cambriano na região central de Goiás.** Anais do XXI CONGR. BRAS. GEOL., SBG, Curitiba, v.26, 1967.

ALMEIDA, F.F.M. **Geochronological division of the Precambrian of South America.** *Rev. Bras. Geoc.* v.I, 1971.

ALMEIDA, F.F.M.; HASUI, Y.; NEVES, B.B.B.; FUCK, R. R **Províncias estruturais brasileiras.** Anais do VIII SIMP. GEOL. NORD, SBG, Campina Grande, p.363-391,1977.

ARANTES, D.; OSBORNE, G.A.; BUCK, P.S.; PORTO, C.G. **The Mara Rosa volcano-sedimentary sequence and associated gold mineralization.** In: BRAZIL GOLD'91, Belo Horizonte: E.A. Ladeira (ed), Balkema, Rotterdam, p. 221-229, 1991.

ARANTES, et al.(cons.). **Seleção de ambientes favoráveis para a prospecção de ouro e cobre na região de Chapada-Mara Rosa - Mineração Maracá Ltda.** Dados compilados e interpretados, Arantes e Associados, v. II, anexos 01-06, 1996.

ARNDT, N.T.; TEIXEIRA, N.A.; WHITE, W.M. **Bizarre geochemistry of komatiites from the Crixás greenstone belt.** *Contrib. Mineral. Petrol.*, 101:187-197, 1989.

BARBOSA, O. et. Al. **Projeto Brasília, Goiás.** PROSPEC S.A/ DNPM, Relatório Inédito, s. ident., il., fotos, mapas e seções geológicas. Petrópolis, 1969, 225 p.

BIONDI, J.C.; PIODEVIN, J.L. **Idade da mineralização e da seqüência do depósito de esmeraldas de santa Terezinha, Goiás, Brasil.** Anais do XXXVIII CONGR. BRAS. GEOL., SBG, Balneário Camboriú, 1:302-304,1994

BLUM, M.L.B. **Superfície Curie da região central de Goiás e relações com geologia, geotectônica e recursos minerais.** Dissertação de Mestrado - Instituto de Geociências da Universidade de Brasília.1995. 82 p.

BURNETT, C.CH. **Application of neural networks to mineral reserve estimation.** Thesis (Ph.D) - Dept. of Mineral Resources Engineering, University of Nottingham, 1995.

CLÁUDIO, D. M.; MARINS, J.M. **Cálculo numérico computacional.** São Paulo: Ed. Atlas S.A, 2000

CORTEZ, L.P. ; SOUZA, A. J. ; DURAO, F.O. **Mineral resources estimation using neural networks and geostatistical techniques.** 27th International Symposium on Computer Applications in the Mineral Industries (APCOM), London, p.305-314, 1998.

COSTA, J.B.S. ; HASUI, Y. **Aspecto do lineamento transbrasiliano na região de Porto Nacional - Natividade, GO.** Anais do XXXV CONGR. BRAS. GEOL., SBG, Belém,5:2208-2216, 1988.

COSTA, S.A.G. **Correlação de seqüência encaixante das esmeraldas de Santa Terezinha de Goiás com os terrenos do tipo Greenstone Belt de Crixás e topologia dos depósitos .** In : Anais do CONGR. BRAS. GEOL., 34, SBG, Goiânia,, v. 2, p.597-614, 1986.

COSTA, S.A.G.; SÁ, W.L. **Garimpos de esmeralda da Santa Terezinha de Goiás, Goiás.** DNPM, 1991.

DANNI, J.C.M.; RIBEIRO, C.C. **Caracterização estratigráfica da seqüência vulcano, sedimentar de Pilar de Goiás e de Guarinos, Goiás.** Anais do XXX CONGR. BRAS. GEOL., SBG, Recife, p. 582-596, 1978.

DANNI, J.C.M.; LEONARDOS, O.H.; ANDRADE, G.F. **Feições vulcânicas das rochas ultramáficas de hidrolina, GO.** Anais do XXXI CONGR. BRAS. GEOL., SBG, Balneário Camboriú, v.4, p.1997-2003,1980.

DANNI, J.C.M.; JOST, H. ; WINGE, M. ; ANDRADE, G.F. **Aspectos da evolução dos terrenos granito, greenstone: exemplo da região de Hidrolina, Goiás.** Anais do XXXIV CONGR. BRAS. GEOL., SBG, Goiânia, p.570,-584,1986.

DANNI, J.C.M. **Os Greenstone Belts da província Tocantins no estado de Goiás, Brasil.** *Rev. Bras. Geoc.*, v.18, n.4, p.381-390,1988.

DENBY, B.; BURNETT, CCH. **GEMNET- Using NN to approximate the location-grade relationship in Mineral Deposits:** Proc. Application of Computers and Operations Research in the Mineral Industry (APCOM XXV). Brisbane, p. 109-114, 1995.

DEUTCH, C. V.; JOURNAL, A G. **GSLIB-Geostatistical software library and user's guide.** Oxford University Press, New York, 340p, 1992.

DRAKE JR., A.A. The serra de Caldas Window, Goiás. U.S.G.S. Prof. Paper 1119/A-B: 1-11, 1980.

DYMINSKI, A .S. **Análise de problemas geotécnicos através de redes neurais**. Tese de Doutorado, Departamento de Engenharia Civil da PUC-Rio de Janeiro),2000.

FORESEE, F.D.; HAGAN, M.T. **Gauss-Newton approximation to bayesian learning**. Proceedings of the 1997 International Joint Conference on Neural Networks, 1997. 6p.

FUCK, R.A. **A faixa Brasília e a compartimentação tectônica da província Tocantins**. Anais do IV SIMP. GEOL. C., OESTE, SBG, Brasília, p. 184-187,1994.

FUCK, R.A. ; MARINI, O.J. **O Grupo Araxá e unidades homotaxiais**. Anais do SIMP.CRÁT. SÃO FRANC. E FAIX. MARG., SBG, Salvador, p.118-129, 1981.

FUCK, R.A.; PIMENTEL, M.M.; D'EL REY SILVA, L.J.H. **Compartimentação tectônica na porção oriental da província Tocantins**. Anais do XXXVIII CONGR. BRAS. GEOL., SBG, Balneário Camboriú , p.215-216, 1994.

HAGAN, M. T. ; MENHAJ, M. B. **Training feedforward networks with the marquardt algorithm**. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989-993,1994.

HAYKIN, S. **Redes neurais princípios e prática**. 2 ed., Bookman, 2001.

INDEPENDENT MINING CONSULTANTS. **Mining feasibility study of the Chapada Project, Brazil**. Relatório interno da Mineração Maracá. Tucson ,1997.

ISAACKS, E. H.; SRISVASTAVA, R. M. **An introduction to applied geostatistics**. New York: Oxford University Press,1989.561p.

JIMMERSON, S. **Chapada resource model**. Memorando interno Echo Bay Mines, 1996.

JOST, H. ; OLIVEIRA, A.M. **Stratigraphy of the Greenstone Belts, Crixás region, Goiás, Central Brazil**. *Journ. South Amer. Earth Scienc.*, v. 4, n.3, p. 201-214. 1991.

JOST, H.; CARMELO, A.C. & MENESES, P.R. **Litologias, relações de contato e estrutura do bloco caiamar, Crixás, Goiás.** Anais do IV SIMP. GEOL. C., OESTE, SBG, Brasília, p. 18-20, 1994

KAPAGERIDIS, I.K. ; DENBY, B. **Ore grade estimation with modular neural network systems; a case study.** Information technologies in the minerals industry via the Internet, Rotterdam: Panagiotou and Michalakopoulos (ed), Balkema, p. 52, 1997.

KAPAGERIDIS, I.K. ; DENBY, B. **Neural network modelling of ore grade spatial variability.** Proceedings of the 8th International Conference on Artificial Neural Networks, London; Springer-Verlag London, v. 1, p.209-214, 1998.

KAPAGERIDIS, I.K.; DENBY, B ; HUNTER, G. **Integration of a neural ore grade estimation tool in a 3D resource modeling package.** Proceedings of the International Joint Conference on Neural Networks., IEEE. Washington, DC, v.6, p. 3908-3912, 1999a

KAPAGERIDIS, I.K., DENBY, B., SCHOFIELD, D. E HUNTER, G. **GEMNET II - A neural ore grade estimation system.** Proceedings of 28th International Symposium on Computer Applications in the Minerals Industry. Kadri Dagdelen, p. 591-598, 1999b.

KUMAR, J.K., KONNO, M. ; YASUDA N. **Subsurface soil-geology interpolation using fuzzy neural network.** *Journal of Geotechnical and Geoenvironmental Engineering*, v. 126, n. 7, p. 632-639, 2000.

KUYUMJIAN, R.M. **Geologia e mineralizações auríferas do Greenstone Belt da faixa Crixás-Go.** Tese (Dissertação de Mestrado) – Instituto de Geociências, Universidade de Brasília, Brasília. 1981.

KUYUMJIAN, R.M. **The geochemistry and tectonic significance of amphibolites from the Chapada sequence, Central Brazil.** (D. Phil. Thesis) - Royal School of Mines, Imperial College of Science and Technology, University of London, London, 1989. 289p.

KUYUMJIAN, R.M. **Geochemistry of archaean komatiitic basalt and speculations on the evolution of greenstone terranes, Goiás, Central Brazil.** Third International Archaean Symposium, Perth, Australia, Extended Abstracts volume, p.257- 258, 1990.

KUYUMJIAN, R.M. **A Trajetória do metamorfismo na região de Chapada, Goiás, Brasil.** Anais do XXXVI Congr. Bras. Geol., Natal, v.3, p. 2007-2017, 1990.

KUYUMJIAN, R.M. **A suggested hydrothermal exhalative origin for the Chapada copper-gold deposit, Brazil.** Symp. Brazil Gold –91, Belo Horizonte, p.231-234, 1991.

KUYUMJIAN, R.M. **Diversity of fluids in the origin of the Chapada Cu-Au deposit, Goiás.** *Rev. Bras. Geociências*, v.25, n.3, p. 203-205, 1995.

KUYUMJIAN, R.M. **Kyanite-staurolite ortho-amphibolite from the Chapada region, Goiás, central Brazil.** *Mineralogical Magazine*, v. 62, n.4, p.501-507, 1998.

MACHADO, E.V. **Novas considerações e integração geológica de pilar de Goiás/Mara Rosa/Porangatu.** Anais do I SIMP. GEOL. C., OESTE, SBG, Goiânia, p. 185-207, 1981.

MAGALHÃES, M.N.; LIMA, A.C.P. **Noções de probabilidade e estatística.** 5.ed. São Paulo: EDUSP. , 2002.

MARCHETTO, C.M.L.(cons.). **Petrographic study report.** Relatório interno Mineração Santa Elina Ind. e Com. S.A. Rio de Janeiro: CLM PETROGRAFIA LTDA, v. 14, 1996.

MARINI, O.J.; FUCK, R.A.; DANNI, J.C.M.; DARDENNE, M.A. **A evolução geotectônica da faixa Brasília e do seu embasamento.** Simpósio sobre o Cráton do São Francisco e suas Faixas Marginais, p.100-115, 1981.

MATLAB Software versão 6.0.0, R12, The MathWorks Inc, 2000.

MINERAÇÃO ALONTE LTDA. **Relatório de reavaliação de reservas da jazida de Chapada.** Relatório interno, v. 2. , 1997.

PEZESHK, S.; CAMP, C.V. ; KARPRAPU, S. **Goephysical log interpretation using neural network.** *ASCE Journal of Computing in Civil Engineering*, v. 10, n. 2, p. 136-142, 1996.

PIMENTEL, M.M.; FUCK, R.A. **Neoproterozoic crustal accretion in Central Brazil.** *Geology*, v.20, p. 375-379, 1992.

PIMENTEL, M.M.; HEAMAN, L.; FUCK, R.A. **Idade do meta, riolito da Seqüência Maratá, Grupo Araxá, Goiás:** Estudo Geocronológico pelos Métodos U, Pb em Zircão, Rb, Sr e Sm, Nd. *An. Acad. Bras. Ci.*, v.64, n.1, 1992.

RIBEIRO FILHO, W. et al. **Projeto geologia da região de Pilar-Mara Rosa**. DNPM/CPRM. Relatório Final Inédito, s.ident., il., mapas e fotografias. Goiânia, v.1, 1978. 144p.

RIBEIRO FILHO, W. **Reavaliação da geologia de Pilar-Mara Rosa**. Simp. Geol. Centro-Oeste 1. Goiânia, Atas.... SBG, v.1, p. 281-296, 1981.

RICHARDSON, S.V.; JONES, J.P. ; KESLER, S.E. **Strontium isotopic geochemistry of pan, African/Brasiliano rocks, Chapada copper deposit, Goiás, Brazil**. *Geol. Rundsch.*, 77:763-770, 1986.

RICHARDSON, S.V.; KESLER, S.E; ESSENE, E.J. **Origin and geochemistry of the Chapada Cu-Au Deposit, Goiás, Brazil**: A metamorphosed wall-rock porphyry copper deposit. *Economic Geology*, v.81, p.1884-1899, 1986.

ROGERS, S.J.; FANG, J.H.; KARR, C.L.; STANLEY D. **A. determination of lithology from well logs using a neural network**. *AAPG – The American Association of Petroleum Geologists Bulletin*, v. 76, n.5, p. 731-739, 1992.

SABOIA, L.A. DE. **Os Greenstone Belts de Crixás e Goiás, GO**. SBG, NCO, boletim n.9, p.44-72, 1979.

SILVA, J.A.; SÁ J.A.G. **Jazida de cobre da Chapada, Mara Rosa, Goiás**. In: DNPM/CVRD, C.Schobbenhaus, C.E.S. Coelho (ed). Principais depósitos minerais do Brasil, v.3, p. 55-60, 1988.

SCHOBHENHAUS, C. et.al. **Carta geológica do Brasil ao milionésimo**. Folha Goiás. MME/DNPM, DGM, 1975.

SOUZA, J.O. ; LEÃO NETO, R. **Mapeamento geológico na área de garimpo de Santa Terezinha de Goiás**. Goiânia, MME/DNPM/CPRM. 75 p.

STRIEDER, A.J.; NILSON, A.A. **Melange ofiolítica nos metassedimentos Araxá de Abadiânia (GO) e implicações tectônicas regionais**. *Rev. Bras. Geoc.*, v. 22, n. 2 p.204-215, 1992.

STURARO, J.R. **Introdução à geoestatística com o Gslib**. VIII Simpósio de Quantificação em Geociências, Rio Claro, 2000.

SWINGLER, K. **Applying neural networks** - A practical guide. *Academic Press Inc.*,1996.

TASSINARI, C.C.G.; MONTALVÃO, R.M.G. DE. **Estudo geocronológico do greenstone belt de Crixás**. Anais do XXXI CONGR. BRAS. GEOL., SBG, Balneário Camboriú, p.2752-2759,1980.

TOLL, D. **Artificial intelligence applications in geotechnical engineering**. Electronic Journal of Geotechnical Engineering, <http://geotech.civen.okstate.edu/ejge/ppr9608,1996>.

VIANA, M. G. et.al. **O arco magmático de Mara Rosa, Goiás: Geoquímica e geocronologia e suas implicações**. *Revista Brasileira de Geociência*, v.25, n.2, p.111-123, 1995.

VULCAN Software versão 3.2, Maptek Pty Ltd, 1998.


WINGE, M. **Evolução dos terrenos granulíticos da província estrutural Tocantins, Brasil Central**. Tese (Dissertação de Doutorado) – Instituto de Geociências, Universidade de Brasília. 1995.

WU, X.; ZHOU, Y. **Reserve estimation using neural networks techniques**. *Computers & Geosciences*. Pergamon Press, v.19, n. 4, p. 567-575,1993.

## APÊNDICE A



---

- SEÇÃO DE SONDAAGEM 1100
- SEÇÃO DE SONDAAGEM 2250
- SEÇÃO DE SONDAAGEM 3100
- SEÇÃO DE SONDAAGEM 3800



LEGENDA

<p>TEORES DE COBRE (%) ( BANCADAS DE 10m )</p> <table border="0"> <tr> <td>REAL</td> <td>REDE NEURAL</td> <td></td> </tr> <tr> <td>0.000</td> <td>0.285</td> <td>Estéril</td> </tr> <tr> <td>0.285</td> <td>0.500</td> <td>Minério baixo teor</td> </tr> <tr> <td>0.500</td> <td>1.000</td> <td>Minério teor médio</td> </tr> <tr> <td>&gt;1.000</td> <td></td> <td>Minério alto teor</td> </tr> </table>		REAL	REDE NEURAL		0.000	0.285	Estéril	0.285	0.500	Minério baixo teor	0.500	1.000	Minério teor médio	>1.000		Minério alto teor	<p>SUPERFÍCIES</p> <ul style="list-style-type: none"> <li><span style="color: blue;">—</span> BASE SAPROLITO</li> <li><span style="color: green;">—</span> CAVA PROJETADA</li> </ul>	<p>ESCALA HORIZONTAL</p> <p>50 0 50 METRO 1 cm is 20 m</p>	<p>DEPÓSITO Cu-Au CHAPADA</p> <p>SEÇÃO DE SONDAGEM</p> <p>1100</p> <p>( BANCADAS DE 10m )</p>
REAL	REDE NEURAL																		
0.000	0.285	Estéril																	
0.285	0.500	Minério baixo teor																	
0.500	1.000	Minério teor médio																	
>1.000		Minério alto teor																	



LEGENDA


TEORES DE COBRE (%) ( BANCADAS DE 10m )

REAL	REDE NEURAL	
0,000	0,285	Estéril
0,285	0,500	Minério baixo teor
0,500	1,000	Minério teor médio
>1.000		Minério alto teor

SUPERFÍCIES

- BASE SAPROLITO
- CAVA PROJETADA

ESCALA HORIZONTAL




DEPÓSITO Cu-Au CHAPADA

SEÇÃO DE SONDAGEM


2250

( BANCADAS DE 10m )



LEGENDA

<p>TEORES DE COBRE (%) ( BANCADAS DE 10m )</p> <p>REAL REDE NEURAL</p> <p>0.000 0.285 Estéril</p> <p>0.285 0.500 Minério baixo teor</p> <p>0.500 1.000 Minério teor médio</p> <p>&gt;1.000 Minério alto teor</p>		<p>SUPERFÍCIES</p> <p>BASE SAPROLITO</p> <p>CAVA PROJETADA</p>		<p>ESCALA HORIZONTAL</p> <p>50 0 50</p> <p>METRO</p> <p>1 cm is 20 m</p>		<p>DEPÓSITO Cu-Au CHAPADA</p> <p>SEÇÃO DE SONDAGEM</p> <p>3100</p> <p>( BANCADAS DE 10m )</p>	
--	--	--	--	--	--	---	--



LEGENDA


TEORES DE COBRE (%) ( BANCADAS DE 10m )

REAL	REDE NEURAL	
0.000	0.285	Estéril
0.285	0.500	Minério baixo teor
0.500	1.000	Minério teor médio
>1.000		Minério alto teor

SUPERFÍCIES

- BASE SAPROLITO
- CAVA PROJETADA

ESCALA HORIZONTAL



DEPÓSITO Cu-Au CHAPADA

SEÇÃO DE SONDAGEM

3800  
( BANCADAS DE 10m )