

## CAPÍTULO 5

### CONCLUSÕES E DISCUSSÕES

Técnicas de análise e integração multi-critérios de dados espaciais aplicadas no complexo alcalino de Poços de Caldas mostraram ser ferramentas poderosas em modelamentos aplicados em pesquisa mineral, na predição das áreas favoráveis à ocorrência de depósitos minerais. Todavia, o sucesso de tal abordagem depende diretamente do grau de conhecimento disponível sobre a geologia da região de estudo, o qual permitirá a definição de parâmetros e relações necessários à definição do modelo prospectivo a ser adotado.

A concepção do modelo prospectivo normalmente é a etapa mais difícil do trabalho, onde a definição das evidências e a importância relativa entre elas será de suma importância para a boa eficiência do modelo adotado. Assim, a elaboração do modelo é fortemente depende do conhecimento que o especialista tem da geologia da área de estudo, incluindo “modelos de depósitos”, além do domínio das técnicas mais adequadas para a integração dos dados.

A utilização da probabilidade condicional (Grau de Confiança) na avaliação quantitativa dos cenários mostrou-se bastante interessante pois permitiu medir o poder explicativo dos cenários de favorabilidade às ocorrências minerais. A utilização desse parâmetro em conjunto com a inspeção visual proporcionou julgamentos mais “precisos”.

A Tabela 5.1 apresenta um resumo sobre o desempenho dos 8 modelos de análise multi-critério usados no presente estudo. Ela indica a soma das áreas (Km<sup>2</sup> e porcentagem (%)) e ocorrências minerais radioativas incidentes, nas classes “alto” e “médio” potencial, além do grau de confiança da classe “alto” potencial e o padrão de saída dos dados.

O modelamento *Booleano* é de fácil implementação, sendo indicado para trabalhos de inferência com dados simplificados em formato temático. Entretanto, a generalização dos dados num estágio inicial da inferência resultou em desempenho regular, sendo o cenário de potencialidade gerado o segundo pior dentre todos, em termos dos aspectos analisados. A rigidez do produto final foi outra característica não favorável, não permitindo variações na graduação dos níveis de prioridade, que em processos de tomada de decisão pode implicar em erros de julgamento. Embora seu desempenho tenha sido moderado, a classe “favorável” encerrou 24 das 48 ocorrências minerais, a mesma quantidade obtida pelas áreas das classes “alto” e “médio” potencial do modelo Média Ponderada.

**TABELA 5.1 – SUMÁRIO DO DESEMPENHO DE CADA MODELO**

Métodos	Classe	Área		Grau de confiança (Classe “alta”)	Ocorrências Minerais (48 no total)	Padrão de saída dos dados
		Km <sup>2</sup>	%			
<i>Booleano</i>	Favorável	32.40	4.45	5.78	24	ruim
<i>Média Ponderada</i>	Alta + Média	30.64	4.21	12.60	24	regular
<i>Fuzzy Mín-Máximo</i>	Alta + Média	37.36	5.14	5.44	28	regular
<i>Fuzzy Média</i>	Alta + Média	30.93	4.25	7.52	26	bom
<i>Fuzzy Ponderado</i>	Alta + Média	30.43	4.18	12.90	27	bom
<i>Fuzzy Gama</i>	Alta + Média	29.06	3.99	6.92	17	ruim
<i>Bayes</i>	Alta + Média	27.54	3.78	6.69	27	regular
<i>Redes Neurais</i>	Alta + Média	28,52	3.92	12.51	25	bom

Os resultados do modelamento baseado em Média Ponderada possibilitaram uma maior flexibilidade na manipulação dos dados em relação ao método *Booleano*, o que implicou numa melhora no processo de inferência. A ponderação dos dados temáticos permitiu uma graduação da importância relativa das evidências, num acréscimo de informação e, conseqüentemente, numa melhora no modelamento dos dados. Todavia, o caráter discreto dos valores não foi totalmente eliminado, o que impossibilitou a melhora da mobilidade nos níveis de tomada de decisão

(fatiamento). O desempenho do cenário gerado foi muito bom, o grau de confiança (12,60) foi o segundo melhor entre as classe “alto” potencial dos demais cenários. Esse cenário e o do *Fuzzy* Ponderado foram os únicos, onde os três principais depósitos. (Mina Usamu Utsumi; Campo Agostinho; e Morro do Ferro) foram mapeados pela classe “alto” potencial.

A teoria da lógica *Fuzzy* foi a que permitiu o maior refinamento no modelamento dos dados, permitindo a representação da variação espacial dos atributos em superfícies contínuas. Entretanto, essas características nem sempre levaram a resultados mais adequados. As funções membros *fuzzy* possibilitaram a incorporação do conhecimento de forma bastante realista, resultando em cenários mais coerentes e menos sujeitos a erros. A abordagem da importação semântica (IS) permitiu a incorporação sobre a natureza imprecisa de contatos litológicos, o que representou uma melhoria na natureza da informação. Outra vantagem da modelagem *fuzzy* é a maior quantidade de operadores o que representa maior flexibilidade na combinação das evidências.

Os modelos *Fuzzy* Mínimo-Máximo e *Fuzzy* Média geraram cenários com desempenhos razoáveis em comparações aos demais. O principal problema nos dois modelos foi os baixos valores de grau de confiança. O moderado desempenho destes modelos está associado diretamente à simplicidade dos operadores, que não permitem a graduação das evidências.

O modelo *Fuzzy* Mínimo-Máximo apresentou problemas também no padrão de saída dos dados, com pontos de concentração que dificultaram o fatiamento. O resultado positivo foi a alta incidência de minerais na classe “alto” potencial, 18 no total. Caso considere-se as classes “alto” e “médio” potencial, o número salta para 28, também a maior incidência entre os demais cenários.

Os cenários dos modelos *Fuzzy* Médio, *Fuzzy* Ponderado e Redes Neurais apresentaram os padrões mais uniformes de distribuição dos valores de saída. Isto permitiu maior flexibilidade nos limiares de corte das classes de potencialidade (tomada de decisão).

O modelo *Fuzzy* Ponderado foi o que obteve o melhor desempenho nos critérios analisados. A classe “alto” potencial obteve o maior grau de confiança (12,90) e em conjunto com a classe “médio” potencial, encerrou 27 ocorrências minerais, a segunda maior coincidência entre os demais cenários. O responsável direto pelo seu sucesso, além da lógica *Fuzzy*, foi a técnica AHP que permitiu, de modo eficaz, a hierarquização das evidências.

O cenário gerado pelo modelo *Fuzzy* Gama foi o que apresentou desempenho menos expressivo dentre todos os modelamentos. A classe “alto” e “médio” potencial encerraram o menor número de ocorrências minerais, 17 no total. E o padrão de saída dos dados foi um dos menos uniformes, apresentando alta concentração em valores baixos. Talvez o principal responsável pelo baixo desempenho, tenha sido o segundo membro do operador (produto algébrico *fuzzy*), visto que o produto de valores menores que “1” tende a diminuir consideravelmente os valores numéricos. Optou-se por um alto valor do expoente gama ( $\gamma=0.85$ ), numa tentativa de minimizar a influência do produto algébrico *fuzzy*, todavia aparentemente, não houve efeito prático.

Embora nem todos os cenários dos modelamentos *Fuzzy* tenham tido desempenho satisfatório, pelas características discutidas acima, na média, pode-se afirmar que o teoria da lógica *Fuzzy* é altamente indicada para estudos de fenômenos naturais.

O método *Bayesiano* constituiu uma abordagem muito interessante ao processo de inferência espacial. A possibilidade do emprego de parâmetros estatísticos, na definição dos ponderadores, é altamente indicada para situações onde torna-se difícil hierarquizar as evidências. Nesses casos o modelo pode servir de guia na definição dos pesos. O estudo do Contraste, para definição do limiar de corte das evidências, também foi bastante interessante pois possibilitou correlacionar mais precisamente as evidências com as verdades de campo. Isso fica claro quando comparamos seus resultados com os do modelo *Booleano*. Uma área menor

( $\text{Área}_{\text{bayes}} = 27,54 \text{ Km}^2$ ) encerrou 27 ocorrências contra 24 do modelo *Booleano* numa área maior ( $\text{Área}_{\text{booleano}} = 32,4 \text{ Km}^2$ ).

O ponto de destaque desse cenário foi a classe “médio” potencial, que obteve o melhor grau de confiança (8,39) em comparação com as demais classes de mesma potencialidade. As classes “alto” e “médio potencial” encerraram 27 ocorrências minerais, a segunda melhor incidência entre os demais cenários.

Apesar dessas características, o cenário gerado pelo método *Bayesiano* apresentou desempenho geral mediano, comparado aos demais. Isso pode estar ligado ao “corte” rígido das evidências na etapa inicial do processo de inferência. Os cortes significaram simplificação dos dados e conseqüentemente redução de informação. Outra característica desse modelamento é a necessidade da existência de verdades de campo (ocorrências minerais) para a realização da tabulação cruzada com as evidências, possibilitando o cálculo de parâmetros de ponderação.

A aplicação das técnicas de Redes Neurais mostrou-se eficiente. O cenário gerado apresentou o segundo melhor desempenho geral, perdendo apenas para o *Fuzzy Ponderado*. A classe “alto” potencial encerrou o segundo maior número de ocorrências minerais (14) e obteve o terceiro maior grau de confiança (12,51). Paradoxalmente, o ponto negativo do modelo é também uma de suas maiores vantagens, a grande quantidade de parâmetros e variáveis que podem ser utilizados, os quais, se não manejados adequadamente, podem alterar consideravelmente o desempenho do modelo. Entretanto, ao mesmo tempo em que isto resulta em dificuldades, permite também simulações muito mais próximas da realidade.

Como sugestão para melhoria em futuros trabalhos de inferência espacial, sugere-se o incremento de mapas de incerteza, os quais poderiam indicar áreas problemáticas nos cenários. Essas regiões poderiam ser eliminadas, ou melhor investigadas em campo para a melhoria do modelo. Adicionalmente, é

recomendável o estudo mais aprofundado de técnicas de fatiamento (migração do ambiente numérico para o ambiente rígido), na tentativa de definir classes temáticas mais coerentes em relação ao agrupamento dos valores numéricos de saída. E, finalmente, um estudo mais aprofundado de outras arquiteturas e paradigmas de aprendizado para redes neurais artificiais, como por exemplo, o aprendizado não-supervisionado, que elimina a necessidade de um padrão de saída para o aprendizado da rede.