



Por que a avaliação da acurácia de mapas previsionais é importante na pesquisa mineral? Uma análise baseada em métodos de estatística multivariada discreta no Prospecto 12 de Outubro, Província Mineral do Tapajós

Thais Andressa Carrino, LGA-UnB; Adalene Moreira Silva, LGA-UnB; Nilson Francisquini Botelho, IG-UnB; Marcelo Pinto, Mapex Mineração; Luiz Carlos Pinheiro Clerot, Mapex Mineração.

Copyright 2011, SBGf - Sociedade Brasileira de Geofísica

This paper was prepared for presentation during the 12th International Congress of the Brazilian Geophysical Society held in Rio de Janeiro, Brazil, August 15-18, 2011.

Contents of this paper were reviewed by the Technical Committee of the 12th International Congress of the Brazilian Geophysical Society and do not necessarily represent any position of the SBGf, its officers or members. Electronic reproduction or storage of any part of this paper for commercial purposes without the written consent of the Brazilian Geophysical Society is prohibited.

Abstract

The accuracy assessment of predictivity maps used in the mineral research comprises the goal of this paper that analyses methods for investigation of this nature. One case study aiming the determination of gold potential areas in the Tapajós Mineral Province is showing through the comparison of the performance of two neural network techniques in relation to truth ground points available by MAPEX Company.

Introdução

Cada vez mais, a produção de mapas de previsão mineral vem sendo requisitada em projetos de exploração mineral. Entretanto, a iniciativa de se gerar mapas de favorabilidade de um determinado bem mineral não supre a questão de validação do resultado, o que é de extrema importância para mostrar se o produto gerado deve ter um grau de alta, média ou baixa credibilidade para nortear trabalhos de campo ou tomadas de decisão. Sobre este aspecto, este artigo apresenta uma discussão e exemplo de análise da exatidão de mapas previsionais para ouro na Província Mineral do Tapajós, especificamente nas abrangências do Prospecto 12 de Outubro, a partir do emprego de duas redes neurais artificiais em dados aerogeofísicos de alta resolução.

A importância da avaliação da exatidão de mapas previsionais

De acordo com Congalton & Green (2009), "o objetivo da avaliação quantitativa da exatidão de mapas temáticos compreende a identificação e medição dos erros do mapa produzido". Quando da produção de um mapa classificado, seja por meio do processamento de dados de sensoriamento remoto, geofísicos etc, a avaliação visual do resultado, rotulando-se de boa, razoável ou ruim não compreende um padrão de avaliação aceitável do desempenho de uma técnica computacional. O resultado gerado somente passa a ter uma validade quando determinados métodos de avaliação estatística passam a ser empregados e, desta forma, tomadas de

decisão podem ser efetuadas sabendo-se a real exatidão dos mapas/guias de prospecção analisados.

Até hoje, tal avaliação estatística de acurácia de resultados não tem sido muito empregada, apesar de sua importância como parte integrante em qualquer projeto de exploração mineral. As principais razões para se analisar a exatidão de mapas produzidos a partir do processamento de imagens de sensoriamento remoto, geoquímicas, geofísicas etc podem ser entendidas da seguinte forma (Congalton 1991, Congalton & Green 2009, Foody 2004) (Figura 1):

- ▶ este enfoque permite o conhecimento do grau de validação do reconhecimento de alvos potenciais eventualmente identificados através de processamento de imagens, modelagens espaciais ou outros métodos computacionais;
- ▶ torna-se possível observar a necessidade de aumentar a qualidade do mapa gerado através da identificação das fontes de erros;
- ▶ permite comparar o desempenho de diferentes técnicas de processamento de imagens e dados multifonte para mapear uma determinada classe (e.g., tipos de minerais de alteração hidrotermal, potencial mineral, litologias etc), concluindo-se qual é(são) a(s) melhor(es) para um determinado estudo de caso.

Matriz de confusão, acurácia total, coeficiente Kappa e teste de hipótese

Um dos principais parâmetros estudados para análise estatística da exatidão de mapas previsionais ou classes geradas pelo emprego de distintos métodos computacionais, compreende o coeficiente de concordância Kappa (Cohen 1960), que é estimado a partir da produção da matriz de erros, também conhecida como matriz de confusão (Congalton 1991, Congalton & Green 2009), conforme ilustrada, esquematicamente na Figura 1.

A estimação do coeficiente Kappa é realizada pelo estimador \hat{k} , de acordo com a Eq. 1:

$$\hat{k} = \frac{p_o - p_c}{1 - p_c}, \quad (\text{Eq. 1})$$

onde p_o é a proporção de casos em concordância (ou seja, classes em concordância com os dados de referência) e p_c é a proporção esperada de acerto por acaso. A estatística \hat{k} varia de +1 a -1 e, em suma, é o

valor que exprime a concordância entre o mapa classificado e o dado de referência, considerando-se também, as ocorrências de omissão e inclusão das classes investigadas.

Além do esforço de se realizar a análise do coeficiente Kappa, também é possível, a partir da matriz de confusão, obter a acurácia (ou exatidão) total, que equivale à razão do número de caso de concordância (diagonal principal da matriz de confusão) pelo número total de elementos analisados (cf., Figura 1).

A estatística \hat{k} é assintoticamente normalmente distribuída, o que permite realizar teste de significância de \hat{k} objetivando-se determinar se a concordância entre o mapa de potencial gerado e os dados de referência é significativamente maior que zero. Para o caso de amostragens independentes, esta análise é realizada através do cálculo da estatística Z, dada pela Eq. 2:

$$Z = \frac{\hat{k}_1}{\sqrt{\text{Var}(\hat{k}_1)}}, \quad (\text{Eq. 2})$$

onde Z é a distribuição normal padrão e $\text{Var}(\hat{k}_1)$ é o estimador da variância do coeficiente Kappa do mapa 1. Dada a hipótese nula $H_0: k_1=0$ e a hipótese alternativa $H_1: k_1 \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$, onde α é o nível de significância do teste de hipótese Z bilateral, considerando-se graus de liberdade infinitos (∞). $Z_{\alpha/2}$, também denominado $Z_{\text{crítico}}$, é obtido a partir da consulta de valores tabelados de acordo com a escolha do nível de significância.

Ainda é possível analisar se dois \hat{k} são significativamente diferentes entre si, através da Eq. 3:

$$Z = \frac{\hat{k}_1 - \hat{k}_2}{\sqrt{\text{Var}(\hat{k}_1) + \text{Var}(\hat{k}_2)}}, \quad (\text{Eq. 3})$$

onde Z é a distribuição normal padrão e $\text{Var}(\hat{k}_2)$ é o estimador da variância do coeficiente Kappa do mapa 2. Dada a hipótese nula $H_0: (k_1 - k_2)=0$ e a hipótese alternativa $H_1: (k_1 - k_2) \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$. Este teste de hipótese é interessante, pois permite a avaliação estatística do desempenho de dois ou mais mapas gerados por diferentes técnicas, implicando na seleção do(s) mapa(s) mais válido para o estudo de caso investigado.

Destaca-se que esta abordagem somente pode ser realizada considerando-se que os estimadores de k sejam independentes, o que em muitos trabalhos nem sempre é uma condição explícita. Para o uso de teste de hipótese considerando-se a repetição dos pontos empregados para a estimação de k, outras abordagens devem ser realizadas, o que não será abordado no presente artigo. Sobre este assunto, Foody (2004) apresenta uma revisão dos principais métodos já propostos para solucionar esta questão.

Estudo de caso – Prospecto 12 de Outubro

Este artigo foca, como meio de exemplificação do uso de métodos estatísticos para a avaliação o desempenho de mapas previsionais, um estudo do potencial aurífero do Prospecto 12 de Outubro, localizado na Província Mineral do Tapajós. As rochas hospedeiras das mineralizações compreendem as vulcânicas ácidas do Grupo Iriri (~1,8 Ga) (Figura 2), como riolitos e riodacitos, havendo a predominância da silicificação como alteração hidrotermal e ocorrências de brechas hidrotermais.

Para a geração de mapas previsionais, dados aeromagnetométricos gradiométricos e aerogamaespectrométricos foram disponibilizados. Estes foram obtidos entre 17 e 30 de janeiro de 2006, e são caracterizados por espaçamento das linhas de vôo e de controle, respectivamente, de 100 m e 2300 m. Imagens de K (%), eTh (ppm), eU (ppm) e dos gradientes horizontais medidos nas direções x e y (G_x e G_y – em nT/m) foram geradas a partir de interpolação pelos métodos curvatura mínima (caso da gamaespectrometria) e bi-direcional (magnetometria), considerando-se o tamanho da célula de 25 m, e a avaliação de dados espúrios e o micronivelamento foram implementados através das respectivas metodologias de Blum (1999) e Minty (1991).

Interpretações de estruturas ENE-WSW, condizentes com a orientação dos *pits* reconhecidos pela Mapex Mineração foram realizadas a partir da análise das imagens dos gradientes medidos e de radar de abertura sintética SAR-R99B (Missão Terra do Meio Oeste, de 2006), em banda L, polarização HH, caracterizadas por ângulo de incidência variando de 45° a 81,10°, resolução espacial em alcance e azimute de 18 m e tamanho de pixel de 15 m. A partir deste resultado, foi gerada a imagem de *buffers*, demarcando-se a influência metalogenética em intervalo de 0-100 m e 100-200 m.

Dados geoquímicos foram considerados como a verdade terrestre a ser comparada com os resultados de modelagens espaciais. Consistem em 188 dados amostrais de ouro em rocha que foram agrupados em duas classes: a classe desfavorável a ouro, referente a valores de ouro em rocha menores que 50 ppb, e a classe favorável a ouro, associada às ocorrências de ouro em rocha maiores ou iguais a 50 ppb. Este valor de corte é considerado prospectivo nas ambiências do Prospecto 12 de Outubro. A discretização destes dados, além dos resultados previsionais marcados por *rank* de favorabilidade (caso da rede neural RBFLN, à qual um corte de probabilidade aurífera $\geq 50\%$ foi estipulado), é necessária, pois os métodos estatísticos citados no item anterior são utilizáveis em *dados categóricos*.

De posse de todos os produtos gerados, montou-se um banco de dados para a aplicação de duas redes neurais.

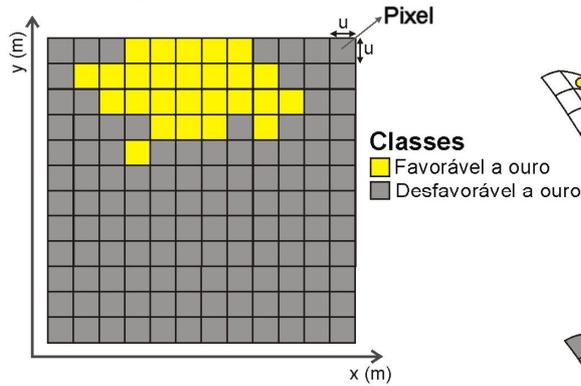
Radial Basis Functional Link Net

Uma função de base radial (y), com vetor central em v, é geralmente definida nos vetores x n-dimensionais pela Eq. 4 (Looney & Yu 2000):

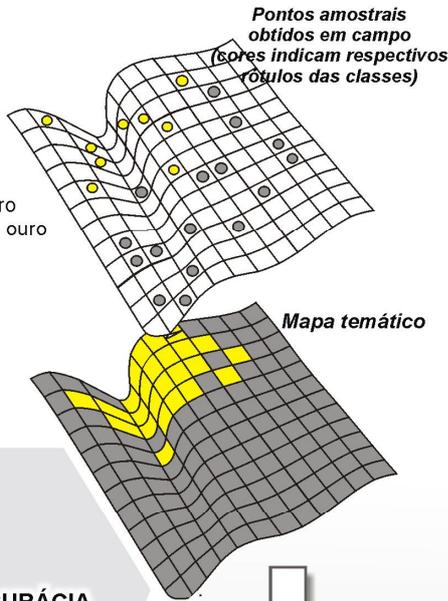
$$y = f(x; v, \sigma) = \exp \left[-\frac{\|x - v\|^2}{(2\sigma^2)} \right], \quad (\text{Eq. 4})$$

onde σ consiste no parâmetro espalhamento, significando a variância da função.

Mapa temático
Resultado da aplicação de uma classificação ou modelagem espacial em dados digitais multifonte



Relação de dados de referência com o mapa temático gerado



MATRIZ DE CONFUSÃO

		Referência		Total
		Favorável a ouro (CLASSE 1)	Desfavorável a ouro (CLASSE 2)	
Mapa	Favorável a ouro (CLASSE 1)	p_{11}	p_{12}	$\sum_{i=1}^2 p_{1i}$
	Desfavorável a ouro (CLASSE 2)	p_{21}	p_{22}	$\sum_{i=1}^2 p_{2i}$
Total		$\sum_{i=1}^2 p_{i1}$	$\sum_{i=1}^2 p_{i2}$	n

$n = \text{número total de elementos analisados}$

ACURÁCIA TOTAL (%)
 $\frac{(p_{11} + p_{22})}{n}$

COEFICIENTE KAPPA (adimensional)

Estimativas do coeficiente Kappa (considera a concordância das classes com a verdade terrestre e os erros de omissão e inclusão) e da variância do mesmo

MÉTODOS DE ESTATÍSTICA MULTIVARIADA DISCRETA

FORMULAÇÃO DE HIPÓTESES:

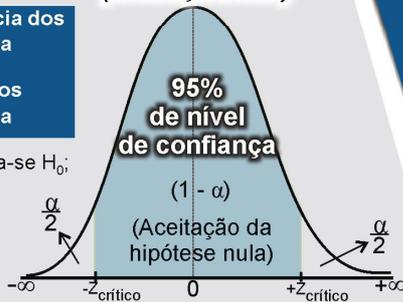
H_0 : não há significância dos estimadores do Kappa

H_1 : há significância dos estimadores do Kappa

Se $Z < Z_{\alpha/2}$, então aceita-se H_0 ;

Se $Z \geq Z_{\alpha/2}$, então rejeita-se H_0

TESTE DE HIPÓTESE Z (Distribuição normal)



Qual o desempenho do mapa gerado para reproduzir a real distribuição espacial do potencial mineral, o que implica também na análise de qual mapa caracteriza-se por maior confiabilidade na investigação de novos alvos cartografados?

Qual a melhor técnica computacional que gerou, no determinado estudo de caso, o melhor resultado para nortear trabalhos de campo e tomadas de decisão num projeto de prospecção mineral?

Qual a fonte de erros dos mapas gerados?

Figura 1. Esquema ilustrando a aplicação de técnicas de estatística multivariada discreta para a averiguação do desempenho de mapas temáticos para o mapeamento do potencial mineral.

O nome radial implica que todos os pontos x equidistantes do centro v retornam os mesmos valores de y na superfície gerada, sendo que tais valores decrescem a medida que os pontos x se afastam do centro v . O uso de funções de base radial permite determinar a

proximidade do vetor de entrada com aqueles que foram determinados na fase de treinamento. Cada vetor x presente na camada de entrada ativa as funções de base radial na camada oculta. Cada um dos M neurônios da camada oculta retorna um valor y para os N neurônios da

camada de entrada, sendo que os valores de y são multiplicados pelos pesos sinápticos u_{mj} nas conexões entre os neurônios da camada oculta e aqueles da camada de saída. Os vetores da camada de entrada são então conectados diretamente aos vetores da camada de saída de forma ponderada pelos pesos sinápticos w_{nj} .

No estudo de caso do Prospecto 12 de Outubro, as imagens de K, eTh, eU (visando a caracterização das rochas hospedeiras das mineralizações – riolitos Iriri) e as imagens dos gradientes medidos Gy e Gx (pois as ocorrências de ouro conhecidas estão associadas com baixos gradientes) foram reclassificadas para 256 classes, e a imagem de *buffers* de lineamentos para duas classes. Os resultados foram integrados de forma a gerar uma matriz de **17420 x 6**. Na etapa de treinamento, foram empregados 15 vetores de treinamento (6 pontos do tipo depósito e 9 pontos do tipo não depósito), 49 funções de base radial e 800 iterações, gerando-se um erro quadrático médio (EQM) e um erro quadrático total (EQT) de 0,0032 e 0,04869, respectivamente. Na etapa de classificação, o EQM equivaleu a 0,0903 e o EQT a 371,3659 para a geração do mapa previsional, mostrado na Figura 2 para favorabilidade aurífera $\geq 50\%$.

Fuzzy Clustering

Considerando os vetores de entrada definidos como $x = (x_1, \dots, x_n)$, onde cada componente x_n representa um pixel dentro de uma população de entidades, o objetivo do algoritmo *Fuzzy Clustering* compreende a separação desta população em classes a partir do agrupamento de um conjunto de vetores de entrada (Looney & Yu 2000).

A etapa do treinamento caracteriza-se pelo agrupamento dos dados em classes (definidas com base nas similaridades dos valores dos vetores de entrada), definindo-se os vetores dos centros dos grupos, a partir de um processo auto-organizável (Looney & Yu 2000). Complementarmente, um processo de junção (*merge*) das classes pode ser realizado, agrupando-se classes com centros muito próximos uns dos outros. Sobre a validação do agrupamento, espera-se obter *clusters* compactos e bem separados uns dos outros para que a validação seja satisfatória. Esta medida de validação é realizada por meio do cálculo do índice Xie-Beni (v), que consiste na razão da compactação pela separação dos k grupos, conforme mostrado na Eq. 5 (Looney & Yu 2000):

$$v = \frac{\left\{ \left(\frac{1}{K} \right) \sum_{k=1}^K \sigma_k^2 \right\}}{\left\{ D_{\min} \right\}^2};$$

$$\sigma_k^2 = \sum_{(q=1, Q)} W_{qk} \left\| x^{(q)} - c^{(k)} \right\|^2, \quad k=1, \dots, K, \quad (\text{Eq. 5})$$

onde D_{\min} é a distância mínima entre os vetores dos centros dos grupos, σ_k^2 é a variância do peso (*fuzzy*) do k -ésimo grupo sobre todos os vetores de entrada Q , e $c^{(k)}$ é o vetor dos centro de cada k -ésimo *cluster*.

Assim, quanto maior D_{\min} , maior é a separação dos grupos, e quanto menor σ_k^2 , maior é a compactação dos grupos. Esta técnica adota a medida da validação de agrupamento de Xie-Beni modificada (Looney & Yu 2000) dada por $\kappa=1/v$, o que significa que um alto valor resultante define que o processo de agrupamento é satisfatório. A última etapa compreende a da classificação do banco de dados, em que um vetor de entrada desconhecido é assimilado ao grupo ao qual fica mais próximo do respectivo vetor do centro do grupo definido na fase de treinamento.

No estudo de caso deste presente artigo, as mesmas imagens reclassificadas para a aplicação da técnica RBFLN foram processadas pelo algoritmo *Fuzzy Clustering*, sendo que na etapa de treinamento foram determinadas quatro classes, gerando-se um valor de $\kappa=2,824$. Na fase de classificação de todo o banco de dados, cada vetor de entrada foi alocado a uma das quatro classes determinadas na fase de treinamento, gerando-se o mapa de potencial aurífero mostrado na Figura 2. A classe indicada neste resultado, sobreposto à imagem do gradiente horizontal medido na direção (Gy), foi selecionada como de alta favorabilidade prospectiva.

Análise dos resultados

Visualmente, os resultados gerados (Figura 2) mapeiam áreas similares com potencial aurífero para a prospecção. Como apenas esta interpretação não é muito válida para tomadas de decisão, a avaliação estatística foi empregada. Para cada mapa gerado, 94 amostras de geoquímica de rocha (verdade terrestre) foram selecionadas *aleatoriamente*, e duas matrizes de confusão foram geradas (Tabelas 1 e 2). A partir destas, foram calculados os estimadores do coeficiente kappa e de suas variâncias, sendo, respectivamente, para os mapas produzidos pelas técnicas RBFLN e *Fuzzy Clustering*, 0,408 e 0,0078, e 0,447 e 0,0085. A acurácia total destes mapas equivaleu, respectivamente, a 70,213% e 72,340%.

Com base nas matrizes de confusão (Tabela 1 e 2), observa-se que o mapa gerado pela técnica RBFLN caracteriza-se por considerável erro de omissão para a classe favorável a ouro (~45%) e baixo para a classe desfavorável a ouro (~13%). Esta relação é invertida quando analisado o total de erro de inclusão, sendo menor para a classe favorável a ouro (~19%) e maior para a classe desfavorável a ouro (~35%). Já o resultado gerado pela técnica *Fuzzy Clustering* apresentou erros similares de omissão e inclusão das duas classes estudadas, da ordem de 27% e 28%.

A comparação do desempenho dos dois mapas para avaliar a qualidade dos mesmos foi realizada empregando-se teste de hipótese Z. Inicialmente, considerando-se um nível de significância de 5%, averigou-se se os estimadores \hat{k}_1 e \hat{k}_2 são estatisticamente diferentes de zero. A partir da aplicação da Eq. 2, obteve-se um valor de Z equivalente a 4,84

para o mapa gerado pela técnica RBFLN e de 4,62 para o mapa produzido pela técnica *Fuzzy Clustering*. Com a relação $Z > Z_{\text{crítico}} (=1,96)$, rejeita-se a hipótese nula (H_0), ou seja, conclui-se que os estimadores do coeficiente Kappa de ambos os mapas gerados são

significativamente diferentes de zero, o que implica na segurança de que ambos os resultados possuem as respectivas concordâncias estimadas de k citadas anteriormente.

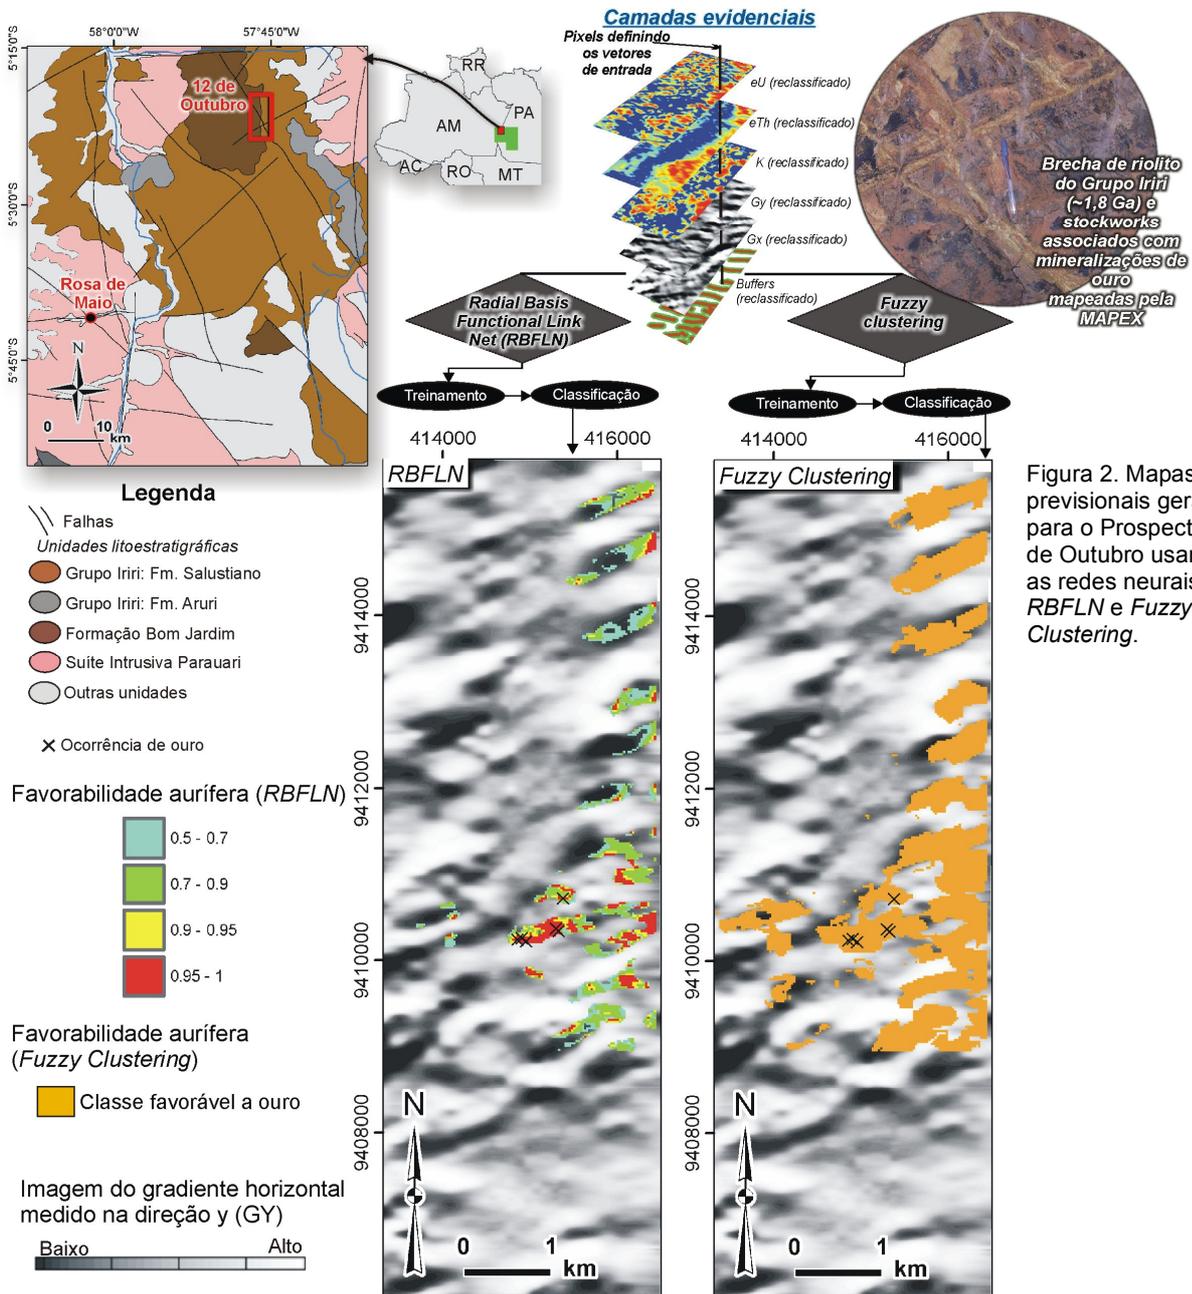


Figura 2. Mapas previsionais gerados para o Prospecto 12 de Outubro usando as redes neurais RBFLN e Fuzzy Clustering.

Considerando-se novamente o nível de significância de 5%, avaliou-se também se ambos os mapas diferem estatisticamente entre si. Para tal, foi aplicada a Eq. 3, obtendo-se um valor de Z igual a 0,30. Com a relação $Z < Z_{\text{crítico}} (=1,96)$, aceita-se a hipótese nula (H_0), ou seja, conclui-se que ambos os coeficientes kappa estimados (\hat{k}_1 e \hat{k}_2) não são significativamente diferentes entre si;

assim, os mapas possuem o mesmo desempenho como guias prospectivos para esta região do Tapajós.

Conclusões

Este trabalho exemplifica que a aplicação de métodos de estatística multivariada discreta para a avaliação da exatidão de dois mapas prospectivos para mineralizações

de ouro no Prospecto 12 de Outubro consiste numa alternativa para uma análise mais crítica do desempenho dos mapas de potencial mineral produzidos, ao invés de realizar apenas uma averiguação visual da espacialização dos resultados. A obtenção dos estimadores dos coeficientes Kappa equivalentes a 0,408 (resultado da rede neural RBFLN) e 0,447 (resultado da rede neural *Fuzzy Clustering*), demonstra que os resultados gerados possuem um desempenho qualificado, segundo os critérios estipulados por Landis & Koch (1977), como **bom**. Adicionalmente, com base na aplicação de teste de hipótese bilateral (Z) e considerando-se um nível de significância de 5%, foi possível averiguar que, estatisticamente, ambos os mapas possuem o mesmo desempenho para a cartografia do potencial aurífero deste estudo de caso. Esta análise é importante para um julgamento criterioso dos resultados obtidos, o que é de fundamental importância para o norteamento da pesquisa exploratória de recursos naturais em qualquer região.

Agradecimentos

Agradecemos ao CNPq pelo projeto CT-Mineral (nº. 555063/2006-2). A.M. Silva e N.F. Botelho agradecem ao CNPq pelas respectivas bolsas de produtividade em pesquisa.

Referências

Blum M.L. 1999. Processamento e interpretação de dados de geofísica aérea no Brasil central e sua

aplicação à geologia regional e à prospecção mineral. Tese (Doutorado em Geologia) - Universidade de Brasília, Brasília-DF, 229 p.

Cohen J. 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurements*, **20**: 37-46.

Congalton R.G. & Green K.G. 2009. *Assessing the accuracy of remotely sensed data: principles and practices*. New York, Boca Raton, FL, 183p.

Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, **37**(1): 35-46.

Foody G.M. 2004. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. *Photogrammetric Engineering & Remote Sensing*, **70**(5): 627-633.

Landis J.R. & Koch G.G. 1977. The measurements of observer agreement for categorical data. *Biometrics*, **33**: 159-174.

Looney C.G, Yu H. 2000. Special software development for Neural Network and Fuzzy Clustering analysis in Geological Information Systems. *Geological Survey of Canada*, 34 p.

Minty B.R.S. 1991. Simple micro-levelling for aeromagnetic data. *Exploration Geophysics*, **22**: 591-592.

Tabela 1. Matriz de confusão gerada para o resultado da aplicação da rede neural *RBFLN*. Coeficiente Kappa (\hat{k}_1) = **0,408** , Var(\hat{k}_1) = **0,0078** e acurácia total = **70,213%**.

Resultado <i>RBFLN</i>	Verdade terrestre		Total	Erro de inclusão
	Classe favorável a ouro	Classe desfavorável a ouro		
Classe favorável a ouro	54.17 %	13.04 %	34.04 %	18.75 %
Classe desfavorável a ouro	45.83 %	86.96 %	65.96 %	35.48 %
Total	100 %	100 %	100 %	54.23 %
Erro de omissão	45.83 %	13.04 %	58.87 %	-

Tabela 2. Matriz de confusão gerada para o resultado da aplicação da rede neural *Fuzzy Clustering (FC)*. Coeficiente Kappa (\hat{k}_2) = **0,447**, Var(\hat{k}_2) = **0,0085** e acurácia total = **72,340%**.

Resultado <i>FC</i>	Verdade terrestre		Total	Erro de inclusão
	Classe favorável a ouro	Classe desfavorável a ouro		
Classe favorável a ouro	72.92 %	28.26 %	51.06 %	27.08 %
Classe desfavorável a ouro	27.08 %	71.74 %	48.94 %	28.26 %
Total	100 %	100 %	100 %	55.34 %
Erro de omissão	27.08 %	28.26 %	55.34 %	-