

Aplicação de rede neural artificial e avaliação da acurácia de mapas previsionais para a seleção de áreas chaves à exploração aurífera nos prospectos Maués, Rosa de Maio e 12 de Outubro, Província Mineral do Tapajós

Thais Andressa Carrino ¹
Adalene Moreira Silva ¹
Nilson Francisquini Botelho ¹
Marcelo Pinto ²
Luiz Carlos Pinheiro Clerot ²

¹ Instituto de Geociências – Universidade de Brasília
70910-900 – Brasília-DF, Brasil
thais.carrino@gmail.com; {adalene, nilsonfb}@unb.br

² MAPEX Mineração, Importação e Exportação Ltda.
Av. Constantino Nery, 2552, Manaus-AM
marcelopinto@mapex.com.br; lclerot@yahoo.com.br

Abstract. This paper comprises a study about the spatial data modeling, including airborne geophysics images, geochemistry data and SAR-R99B images, for the predictivity of gold deposits in the western portion of Tapajós Mineral Province (Brazil). Maués, Rosa de Maio and 12 de Outubro prospects were analyzed through the artificial neural network named Radial Basis Functional Link Net (RBFLN). The high favorability areas for gold exploration were quantified and validated through data of current mapped gold occurrences, using the error matrix, overall accuracy and Kappa coefficient.

Palavras-chave: prospecção aurífera, rede neural artificial, acurácia de mapas previsionais; gold prospecting, artificial neural network, accuracy of the predictivity maps.

1. Introdução

O emprego de modelagens de dados espaciais em terrenos *greenfield*, ou seja, com baixo conhecimento geológico, pode atuar como importante meio de inferência prospectiva em estudos de caso particulares. Neste tipo de terrenos, o que comumente se utiliza são dados de aerolevantamentos regionais fornecidos pelo Serviço Geológico do Brasil, ou de detalhe, adquiridos por empresas privadas, além de imagens de sensoriamento remoto óptico ou de radares imageadores. Apesar da fointerpretação ser amplamente empregada para analisar tais conjuntos de dados, as modelagens espaciais fornecem subsídios mais refinados na tentativa de realçar classes ou padrões de feições geológicas que indiquem os principais vetores de exploração mineral, considerando-se a adequação do uso das inúmeras técnicas atualmente existentes.

As modelagens espaciais guiadas pelos dados (e.g., redes neurais) caracterizam-se pelos parâmetros dos modelos serem calculados a partir de pontos de treinamento conhecidos. Tais técnicas são condizentes em aplicações quando o modelo metalogenético de uma região ainda não é totalmente conhecido, o que usualmente ocorre em terrenos do tipo *greenfield*.

Tomando-se como estudos de caso três prospectos auríferos da Província Mineral do Tapajós, caracterizados por diferentes rochas hospedeiras e estilos de mineralizações, este artigo aborda o uso de dados geoquímicos, aerogeofísicos de alta resolução, imagens SAR-R99B e produtos fointerpretativos para aplicação de uma rede neural artificial com a finalidade de geração de mapas previsionais. Por sua vez, a análise da acurácia dos mapas produzidos também será focada, pois compreende uma etapa fundamental para a quantificação de erros para estes que serão os guias prospectivos para ouro nas regiões abordadas. Os prospectos investigados compreendem o Maués, o

Rosa de Maio e o 12 de Outubro (Figura 1), localizados na maior província aurífera do Brasil.

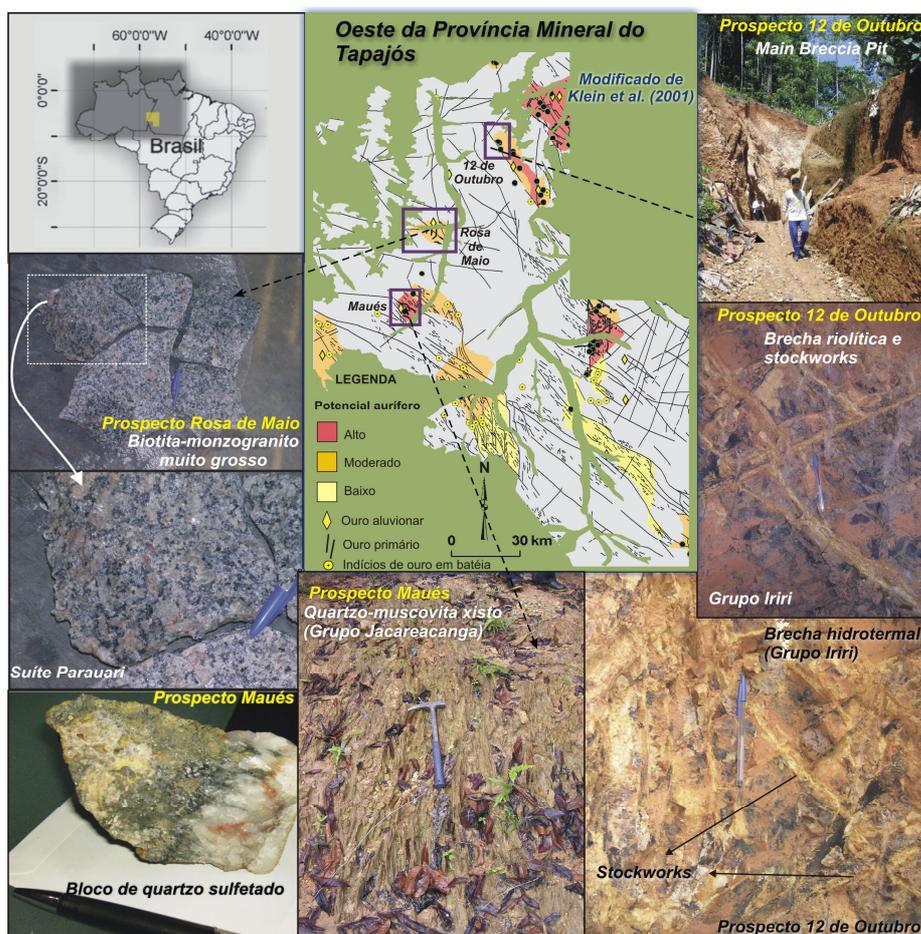


Figura 1. Localização dos prospectos auríferos abordados neste artigo e exemplos de afloramentos verificados em campo.

2. Contexto geológico das áreas de estudo

A Província Mineral do Tapajós (PMT) caracteriza-se por terrenos paleoproterozóicos incluídos na Província Tapajós-Parima, Cráton Amazônico. Os prospectos aqui abordados, geologicamente, pertencem às seguintes ambiências (Klein et al., 2001; Carrino, 2010): (a) Prospecto Maués: rochas metassedimentares do Grupo Jacareacanga, unidade mais antiga da província (~2,1 Ga) são hospedeiras de mineralizações de ouro, sendo verificado em campo, sulfetação, com domínio de pirita, em blocos de quartzo, e foliação N20W com mergulhos verticais a subverticais de quartzo-muscovita xistos; (b) Prospecto Rosa de Maio e Bandeirante: monzogranitos são comumente encontrados nestas ambiências, e são pertencentes à Suíte Intrusiva Parauari (~1,8 Ga). A feldspatização compreende a alteração dominante; (c) Prospecto 12 de Outubro: mineralizações auríferas estão associadas a riolitos e brechas hidrotermais, incluídas na unidade vulcânica ácida de 1,8 Ga denominada Grupo Iriri. A silicificação associadas às mineralizações é evidente nesta região do Tapajós.

3. Materiais

Os materiais selecionados consistem em: (a) dados aerogamaespectrométricos e aeromagnetométricos gradiométricos de 2006, marcados por alta resolução e disponibilizados pela empresa Mapex Mineração, Importação e Exportação Ltda. As linhas de vôo e de controle variam a cada prospecto da seguinte maneira: 75 m e 750 m para o Rosa de Maio; 100 m e 2300 m para o 12 de Outubro; 400 m e 4500 m para o Maués; (b) imagens SAR-R99B da Missão Terra do Meio Oeste, caracterizadas por banda L, polarização HH, resolução espacial em alcance e azimute de 18 m, tamanho de

pixel de 15 m, 8 *looks* e ângulo de incidência variando de 45° a 81,10° (com visada para oeste); (c) dados geoquímicos de ouro em solo e em rocha cedidos pela empresa Mapex Mineração, Importação e Exportação Ltda. para as áreas dos prospectos Maués (110 amostragens para ouro em rocha), Rosa de Maio (558 e 7323 amostragens, respectivamente, para ouro em rocha e solo) e 12 de Outubro (189 amostragens para ouro em rocha). As análises para ouro em solo foram realizadas pelo método *Fire Assay* (fusão e copelação), enquanto dados geoquímicos de rocha foram obtidos a partir de análises no Laboratório ACME – Analítica Laboratórios Ltda., Canadá. As análises foram realizadas segundo as rotinas 4a e 4b.

4. Processamento de imagens e interpretações

Os dados aerogamaespectrométricos foram analisados quanto a possíveis existências de valores negativos que foram corrigidos e, posteriormente, interpolados por meio da aplicação da técnica curvatura mínima e micronivelados a partir da metodologia de Minty (1991). Os dados aeromagnetométricos gradiométricos foram analisados por meio dos métodos Parâmetro P e Diferença Quarta (Blum, 1999) para identificação de possíveis inconsistências. Em todos os levantamentos, não foram observadas inconsistências não justificáveis. O método bi-direcional foi escolhido para interpolação dos dados e o micronivelamento foi realizado segundo Minty (1991). Os seguintes tamanhos de células foram selecionados: 15 m para o prospecto Rosa de Maio; 100 m para o prospecto Maués e 25 m para o prospecto 12 de Outubro. Foram geradas as imagens dos canais de K (%), eTh (ppm), eU (ppm), contagem total ($\mu\text{R/h}$), da razão K/eTh e do Parâmetro F (Efimov, 1978), além das imagens dos gradientes horizontais medidos nas direções x e y (G_x e G_y), do campo magnético anômalo (CMA), das derivada horizontais e vertical de primeira ordem do CMA para produção da imagem da Amplitude do Sinal Analítico (ASA) (Nabighian, 1972).

As imagens SAR-R99B foram corrigidas quanto ao padrão de antena, usando-se uma função de correção de ordem 5. Filtros adaptativos para redução de *speckle* não foram usados em virtude o formato *multilook* dos dados originais. A correção geométrica foi realizada usando-se 82 pontos de controle, resultando num erro quadrático médio de 17,58 m.

Os dados de geoquímica de ouro em solo do prospecto Rosa de Maio foram processados por meio da simulação indicatriz sequencial (SIS) (Goovaerts, 1997), gerando-se 500 imagens equiprováveis, a partir das quais, foi produzida a imagem da média das simulações. Optou-se pela geração da imagem de corte de 25% de probabilidade de ocorrência de anomalias de ouro maiores ou iguais a 50 ppb.

A partir das imagens de radar de abertura sintética e das imagens dos gradientes horizontais medidos e da ASA, interpretações de estruturas nas três regiões abordadas foram realizadas, para criação de *buffers*, a fim de determinar espacialmente áreas de influência metalogenéticas a serem ponderadas no processamento de rede neural artificial. A determinação dos *trends* principais foi conduzida pelas observações feitas em campo e pelas informações cedidas pela MAPEX: feições NW-SE associadas ao *trend* aurífero na região do prospecto Maués; estruturas ENE-WSW associadas a baixos gradientes magnéticos em íntima associação com ocorrências de ouro no prospecto 12 de Outubro; e lineamentos E-W, NE-SW e NNE-SSW associados ao prospecto Rosa de Maio. A ocorrência de feldspatização no Prospecto Rosa de Maio favorece a utilização de produtos gamaespectrométricos que ressaltam K, como razão K/eTh e o Parâmetro F. No caso do Prospecto 12 de Outubro, a silicificação gera uma atenuação sutil dos dados radiométricos que, considerando rochas riolíticas do Grupo Iriri não mineralizadas, são originalmente caracterizadas por altas contagens da radiação gama. Para o Prospecto

Maués, a caracterização de alterações hidrotermais ainda é inicial; alto K é verificado no domínio das rochas hospedeiras de ouro, mas preliminarmente, devem estar relacionadas com a composição metassedimentar dos quartzo-muscovita xistos do Grupo Jacareacanga.

5. Aplicação de rede neural artificial e análise da acurácia de mapas previsionais

Para o conjunto de dados associado aos prospectos Maués, Rosa de Maio e 12 de Outubro, a rede neural artificial *Radial Basis Functional Link Net* (RBFLN) (Looney e Yu, 2000) foi empregada, pois não necessita de um conhecimento *a priori* do modelo metalogenético dos depósitos (visto que tal preceito ainda é questionável nestas áreas), além de possibilitar a extração de padrões ocultos de dados que podem ser imperceptíveis aos seres humanos e aos métodos estatísticos convencionais (Brown et al., 2000), e não ser tão dependente de um grande número de pontos de treinamentos (ocorrências minerais conhecidas).

Uma RBFLN é aplicada a um conjunto de dados pontuais (pontos de treinamento) e rasterizados (planos de informação) (Figura 2 (a)), e é formada por três camadas: a camada de entrada (composta por N neurônios que estão associados com os vetores de treinamento), a camada oculta (formada por M neurônios, estes representados pelas funções de base radial), e a camada de saída (formada por J neurônios) (Looney e Yu, 2000) (Figura 2 (b)). 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} . Desta maneira, cada um dos J neurônios da camada de saída é calculado por meio do somatório dos valores de y multiplicados pelos pesos sinápticos u_{mj} e dos valores de x multiplicados pelos pesos sinápticos w_{nj} (Figura 2 (b)). A fase de treinamento é realizada com uma amostra de q vetores de entrada (vetores de treinamento) e um conjunto de q vetores de saída conhecidos associados. Estes q vetores estão associados aos pixels correspondentes aos pontos do tipo depósito e não depósito. Nesta etapa, parâmetros ajustados da rede neural são ‘aprendidos’ e armazenados para, posteriormente (etapa de classificação), serem aplicados a todos os vetores de entrada do banco de dados, gerando-se um mapa previsionais em que cada pixel está associado a um valor entre 0 e 1 (Porwal et al., 2003).

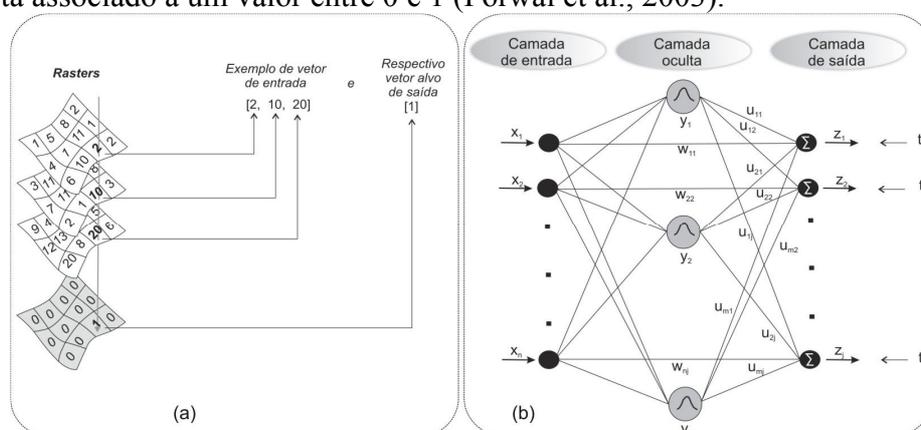


Figura 2. Aplicação da RBFLN, considerando os dados de entrada vetorizados (a) e a arquitetura de uma RBFLN (b), com indicação de N vetores de entrada, M nós na camada oculta e J nós na camada de saída, além dos pesos sinápticos w_{nj} e u_{mj} (Modificado de Looney e Yu, 2000). t = vetor alvo de saída.

A análise da acurácia proposta neste artigo é caracterizada pela produção da matriz de confusão, além do cálculo da acurácia total e do coeficiente de concordância Kappa (Congalton e Green, 2008). Optou-se pela comparação dos mapas gerados pelo uso da rede neural com dados de verdade terrestre disponíveis, no caso, pontos geoquímicos de ouro em rocha. Duas classes para a análise foram comparadas: **(a) *classe favorável a ouro***, relacionada com anomalias de ouro em rocha maiores ou iguais a 50 ppb (verdade terrestre) e com a classe de alta prioridade aurífera do mapa gerado (no caso, junção das classes de muito alta/alta/moderada favorabilidade para ouro – cf., Figura 3); **(b) *classe desfavorável a ouro***, marcada por ouro em rocha menor que 50 ppb (verdade terrestre) e com a classe de baixa favorabilidade para ouro que, por sua vez, não será mostrada nos mapas previsionais produzidos. Destaca-se que foram disponibilizados, aos prospectos abordados neste artigo, os seguintes dados de verdade terrestre: Prospecto Maués (166 pontos geoquímicos, sendo 110 de alta prospectividade e 56 de baixa prospectividade); Prospecto Rosa de Maio (558 pontos geoquímicos, sendo 269 de alta prospectividade e 289 de baixa prospectividade); Prospecto 12 de Outubro (189 pontos geoquímicos, sendo 124 de alta prospectividade e 65 de baixa prospectividade).

5.1. Prospecto Maués

Neste estudo de caso, foram determinados cinco pontos de treinamento (ocorrências de ouro – Grotas da Gono, do Edse e do Bibiu, Filão Velho, Baixão do Filão), os pontos do tipo não depósito (33), além das camadas evidências associadas às imagens de K, eTh, eU, da razão K/eTh e do parâmetro F para o realce das rochas metassedimentares hospedeiras das mineralizações, além da ASA e da imagem de *buffers* de lineamentos NW-SE interpretados com base na imagem SAR-R99B (Figura 3). Destaca-se que as distâncias dos *buffers* equivaleram aos intervalos de 0-100m e 100-200 m.

As imagens de entrada foram reclassificadas em 256 classes e, posteriormente, combinadas de forma a gerar uma matriz de 91294 linhas por 7 colunas (número das variáveis associadas às imagens de entrada). Na etapa de treinamento, foram selecionadas 61 funções de base radial e 900 iterações, além dos 38 vetores de treinamento, gerando-se um erro quadrático médio (EQM) de 0,001 e um erro quadrático total (EQT) de 0,03790. Na fase de classificação, estes erros passaram, respectivamente, a 0,1548 e 367,468, e o mapa previsionais foi gerado e reclassificado por prioridade de favorabilidade para ouro designada por alta e moderada (Figura 3), totalizando 16,475 km² de área.

A partir desse mapa, observa-se que a favorabilidade na região do prospecto Maués está associada à região limítrofe dos metassedimentos do Grupo Jacareacanga com os granitos da Suíte Intrusiva Parauari. Neste sentido, considerando-se que os alvos de interesse estão demarcados pelo alto e moderado grau de prospectividade, pode-se verificar que a ocorrência aurífera mapeada pela CPRM (Klein et al., 2001) está validada na área de alta favorabilidade (Figura 3). A matriz de confusão foi gerada, resultando na análise de uma acurácia total do mapa equivalente a 62,651% e um coeficiente Kappa igual a 0,179.

5.2. Prospecto Rosa de Maio

Foram selecionadas as imagens dos gradientes medidos Gx e Gy, da ASA, as estruturas fotointerpretadas na imagem SAR, além da imagem de ouro em solo gerada pela SIS (Figura 3). No caso das estruturas, *buffers* foram criados com as seguintes distâncias: 0-100 m, 100-200 m e 200-300 m. Inicialmente, as imagens gamaespectrométricas seriam utilizadas na modelagem, a fim de realçar o radioelemento K. Entretanto, as condições ambientais predominantes aliadas à boa

resolução deste aerolevanteamento, atuaram de forma a realçar aluviões e solos, os quais obliteram as respostas de rochas ou mesmo de alterações hidrotermais de interesse. Por tal razão, não se justifica aqui o uso de tal acervo de imagens para este estudo de caso.

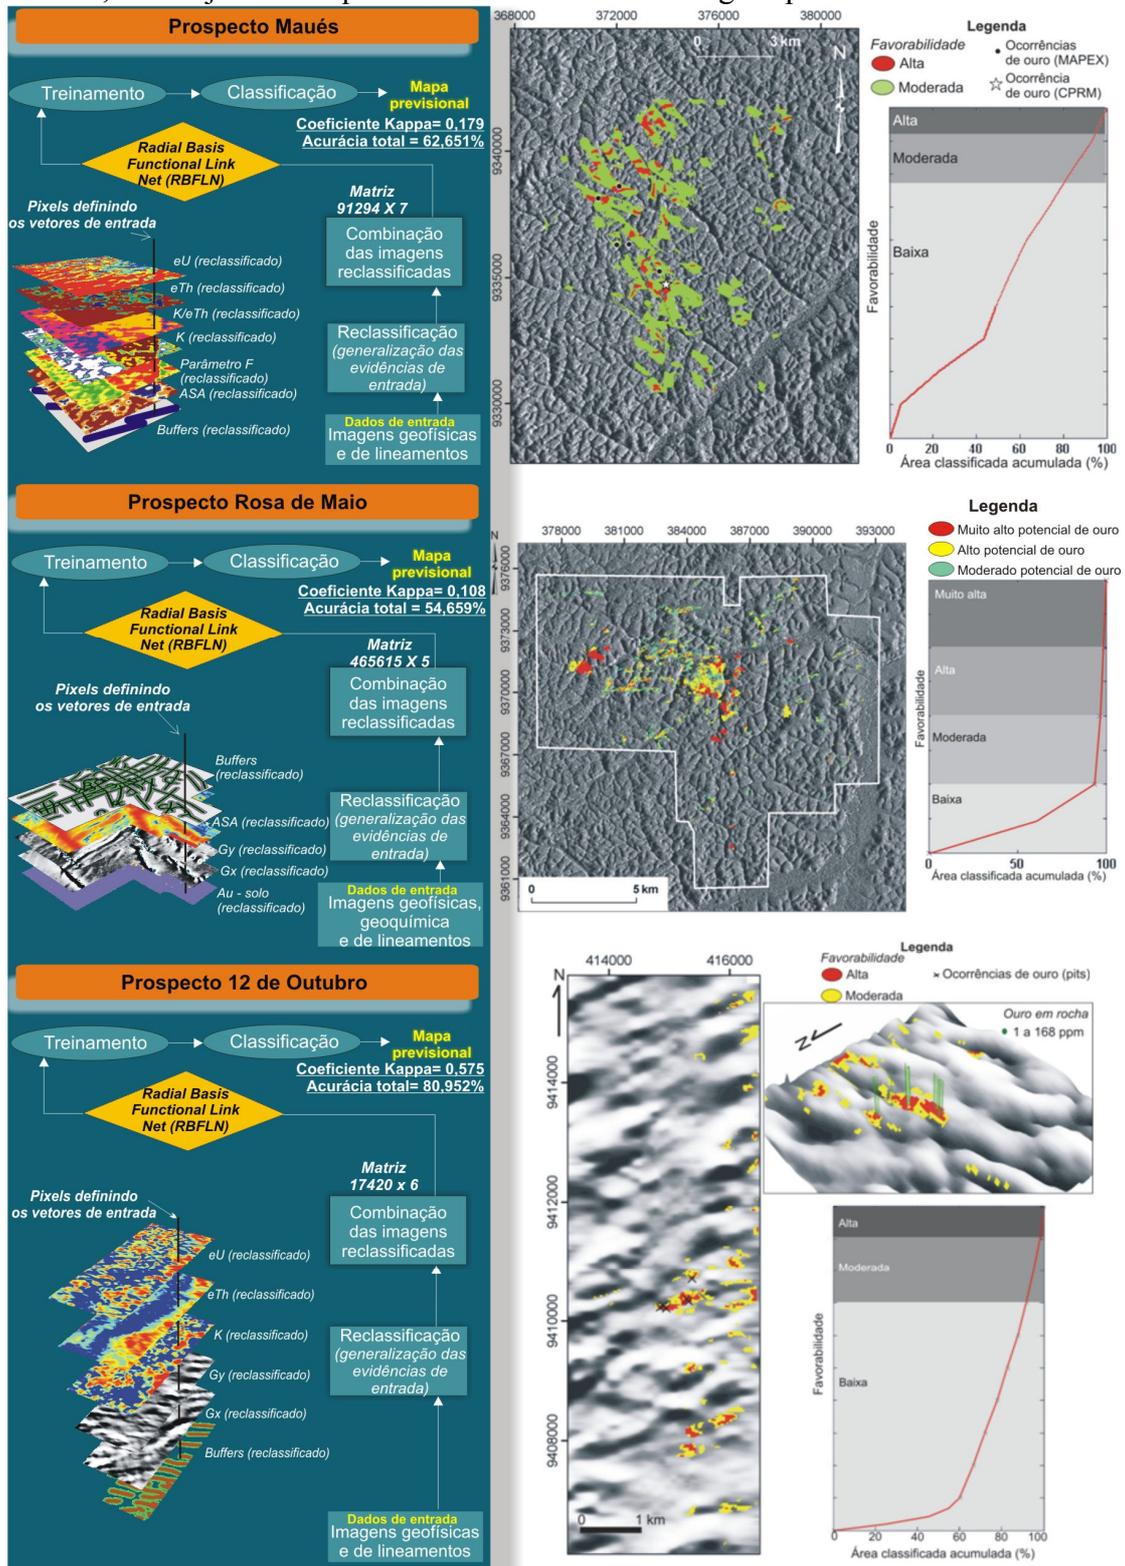


Figura 3. Aplicação da rede neural artificial RBFLN e geração de mapas previsionais para ouro nos prospectos Maués, Rosa de Maio e 12 de Outubro.

As imagens de entrada foram reclassificadas para 256 classes e integradas de forma a gerar um conjunto de dados representado por uma matriz de 465615 x 5. Os pontos de

treinamentos empregados constituem 13 ocorrências anômalas de ouro em rocha, enquanto os pontos do tipo não depósito equivaleram a 21. Desta forma, 34 vetores de treinamento foram utilizados na etapa de treinamento da rede neural, assim como 45 funções de base radial e 700 iterações, gerando-se um EQM de 0,0224 e um EQT de 0,76090. Os dados obtidos durante esta fase de aprendizado da rede foram empregados para a fase da classificação de todos os 465615 vetores de entrada, gerando-se um mapa previsional associado a um EQM e a um EQT de 0,0289 e 882,5350, respectivamente. O resultando foi reclassificado em graus de favorabilidade moderada, alta e muito alta, conforme apresentado na figura 3, em sobreposição à imagem SAR-R99B (L_{hh}). Estas áreas de alta prioridade prospectiva totalizam 6,798 km². Constatou-se, por meio da produção da matriz de confusão, uma acurácia total de 54,659% e um coeficiente Kappa de 0,108 do mapa produzido.

5.3. Prospecto 12 de Outubro

As imagens selecionadas para o processamento equivalem as de K, eTh, eU (visando a caracterização das rochas hospedeiras das mineralizações – riolitos Iriri), as imagens dos gradientes medidos Gy e Gx (pois as ocorrências de ouro conhecidas estão associadas com baixos gradientes), e a imagem de *buffers* de lineamentos ENE-WSW, que foram interpretados e caracterizados por duas classes de distâncias: entre 0-100 m e outra entre 100-200 m. Todas as imagens citadas foram reclassificadas para 256 classes e integradas 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 EQM e um 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. Este, por sua vez, foi reclassificado por prioridades alta, moderada e baixa à prospecção de ouro, conforme visualizado na figura 3.

O mapa previsional gerado mostra que os principais alvos mapeados pela empresa Mapex (pontos de treinamento da rede neural) foram classificados por prioridade prospectiva moderada a alta. Estas regiões prioritárias à prospecção totalizam 0,505 km² de área. O resultado gerado (Figura 3) foi avaliado por meio da confecção da matriz de confusão, obtendo-se uma acurácia total de 80,952% e um coeficiente Kappa de 0,575.

6. Discussões e conclusões

Os mapas prospectivos produzidos com base na rede neural artificial RBFLN (Figura 3) objetivam a tentativa de distinção de padrões que possam estar relacionados com áreas mais prospectivas a ouro. No entanto, o uso de imagens gamaespectrométricas mostrou-se parcialmente útil, pois quanto maior a resolução dos dados, maior foi também o discernimento de assinaturas associadas com coberturas de solos e aluviões, conforme discutido em detalhe em Carrino (2010). Para o Prospecto Rosa de Maio, tais obliterações foram fundamentais como justificativa à retirada de imagens gamaespectrométricas do processo de modelagem, pois de forma alguma iriam dar representatividade a um ambiente geológico associado diretamente com o sistema mineralizador. Apesar de este prospecto ser caracterizado por dados aerogeofísicos e geoquímicos de maior resolução, obteve-se uma acurácia total média e um baixo índice de concordância Kappa, pois poucos dados de entrada disponíveis foram empregados na modelagem. Um dado complementar a ser empregado nesta região compreende o da polarização induzida (IP), o que compreenderia mais uma camada de dados a ser utilizada em modelagens espaciais para previsão aurífera. Uma acurácia total média e um baixo coeficiente Kappa também foram obtidos ao mapa prospectivo do Prospecto

Maués, o que é justificável pelo menor conhecimento geológico desta região, menor densidade de amostragem dos dados aerogeofísicos e menor quantidade de pontos geoquímicos de ouro em rocha (verdade terrestre). Já no caso do mapa produzido do Prospecto 12 de Outubro, obteve-se alta acurácia total e coeficiente Kappa de $\sim 0,5$. Esta área é marcada por melhor conhecimento geológico e dados aerogeofísicos de boa resolução, o que favoreceu a qualidade do mapa previsional. Em todos os casos, deve-se lembrar que o desempenho dos resultados gerados é dependente também dos parâmetros usados no processamento da rede neural.

Nota-se, em inúmeros trabalhos científicos, que a análise estatística da acurácia de mapas de potencial mineral ainda é pouco explorada, sendo o maior foco voltado à análise do desempenho de diferentes técnicas computacionais de forma visual (qualitativa). O que se pode concluir é que não apenas a iniciativa de se gerar mapas previsionais é importante, mas também a avaliação estatística dos mesmos é imprescindível para obter, quantitativamente, um maior ou menor grau de credibilidade dos resultados produzidos, o que é de fundamental importância para o planejamento de trabalhos de campo e de tomadas de decisão em qualquer etapa de um projeto de prospecção mineral.

Agradecimentos

Agradecemos à UnB pelo suporte técnico, ao CNPq pelo projeto CT-Mineral (nº. 555063/2006-2), e à CAPES pela bolsa de mestrado. A.M. Silva e N.F. Botelho agradecem ao CNPq pelas respectivas bolsas de produtividade em pesquisa.

Referências bibliográficas

- Blum M.L. 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., 1999.
- Brown W.M., Gedeon T.D., Groves D.I., Barnes R.G. Artificial neural networks: a new method for mineral prospectivity mapping. *Australian Journal of Earth Sciences*, v.47, n. 4, p. 757-770, 2000.
- Carrino, T.A. Geotecnologias aplicadas ao reconhecimento de áreas-chaves à exploração aurífera na Província Mineral do Tapajós. Dissertação de mestrado em Geologia, Universidade de Brasília, DF-Brasília, 192 p., 2010.
- Congalton, R.G. e Green, K.G. *Assessing the accuracy of remotely sensed data: principles and practices*. New York, Boca Raton, FL, 183p., 2008.
- Efimov A.V. Multiplikativniyi pokazatel' dlja vydelenija endogennykh rud aerogamma-spectrometricheskimi dannymi. In: *Metody rudnoj geofiziki*, Leningrado, Nauchno-proizvodstvennoye ob'edinenie geofizika Ed., 59-68., 1978.
- Goovaerts P. *Geostatistics for natural resources evaluation*. London, Oxford University Press, 483 p., 1997.
- Klein E.L., Almeida M.E., Vasquez M.L., Bahia R.B.C., Santos M.L.E., Ferreira A.L. Geologia e recursos minerais da Província Mineral do Tapajós. Folhas Vila Mamães Anã (SB.21-V-D), Jacareacanga (SB.21-Y-B), Caracol (SB.21-X-X), Vila Riozinho (SB.21-Z-A) e Rio Novo (SB.21-Z-C). Estados do Pará e Amazonas. Escala 1:500.000. Brasília: CPRM/DIEDIG/DEPAT, 2001, 81 p, 2001.
- Looney C.G., Yu H. Special software development for Neural Network and Fuzzy Clustering analysis in Geological Information Systems. *Geological Survey of Canada*, 34 p., 2000.
- Minty B.R.S. Simple micro-levelling for aeromagnetic data. *Exploration Geophysics*, 22: 591-592, 1991.
- Nabighian N.M. The analytic signal of two-dimensional magnetic bodies with polygonal cross section: its properties and use for automated anomaly interpretation, *Geophysics*, 37: 507-517, 1972.
- Porwal A., Carranza E.J.M., Hale M. Artificial neural networks for mineral-potential mapping: a case study from Aravalli province, western India. *Natural Resources Research*, v. 12, n. 3, 155-171, 2003.