


Mostra a variação das concentrações relativas dos três radioelementos relacionando-os com as cores vermelho (K-red), verde (G-green) (Th, ppm) e azul (B-blue)(Eu, ppm). O espectro de cores variando do branco, quando condizente as máximas concentrações relativas nos três radioelementos, até o preto, para os mínimos valores relativos.



No mapa de gradiente total a anomalia magnetométrica é centralizada em relação ao corpo causativo, o caráter dipolar é suprimido, o que simplifica a interpretação. Todavia, dimensões horizontais na anomalia em relação ao corpo causativo são extrapoladas. Recomenda-se a utilização deste produto para realçar a distribuição de rochas/minerais magnéticos na área, e também como forma de simplificar a interpretação dos quadros. A deconvolução Euler utiliza derivadas do campo magnético anômalo para estudar a geometria das fontes magnetométricas localizadas em subsuperfície. Neste trabalho foi empregado o índice 1 para a deconvolução de Euler com o intuito de realçar as estruturas lineares magnéticas da área.

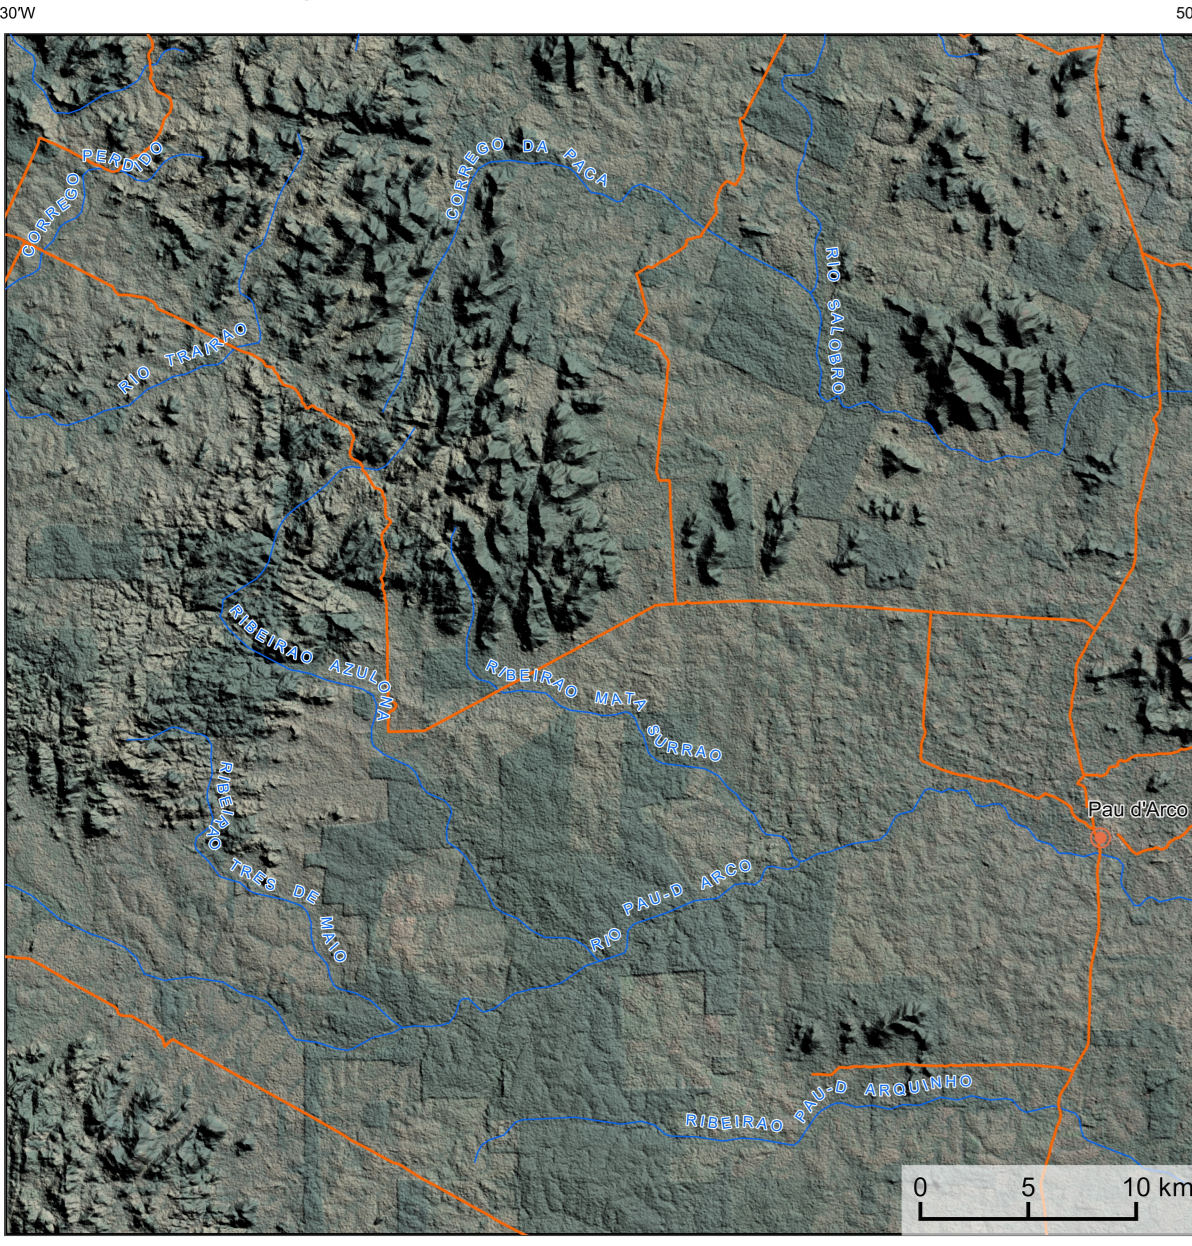
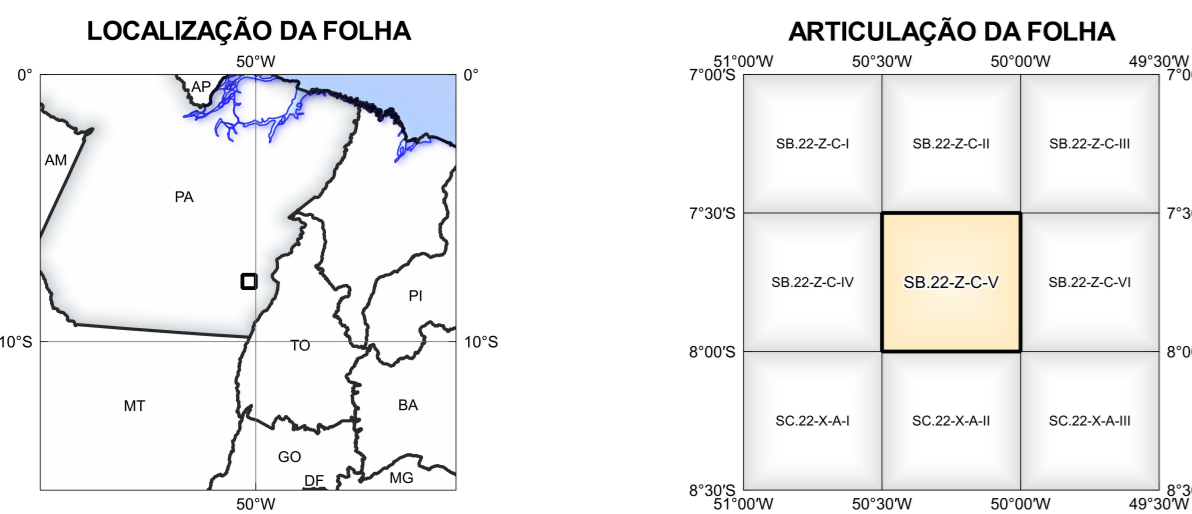


IMAGEM GOOGLE EARTH - NOVEMBRO 2021.



LOCALIZAÇÃO DA FOLHA

ARTICULAÇÃO DA FOLHA

Grid of sheet numbers: SB.22-Z-C-I, SB.22-Z-C-II, SB.22-Z-C-III, SB.22-Z-C-IV, SB.22-Z-C-V, SB.22-Z-C-VI, SB.22-Z-C-VII, SB.22-Z-C-VIII, SB.22-Z-C-IX, SB.22-Z-C-X, SB.22-Z-C-XI, SB.22-Z-C-XII.

Com objetivo subsidiar de informações geocientíficas as iniciativas e projetos de pesquisa mineral do setor privado, o Serviço Geológico do Brasil-CPRM disponibiliza diversos produtos que visam auxiliar na definição de áreas potenciais para novas descobertas. Este novo produto denominado 'carta de anomalias' é apresentado para diversas áreas do território brasileiro que incluem províncias minerais consolidadas ou em consolidação. A 'carta de anomalias' é suportada por um banco de dados de imagens geofísicas, geológicas, geoquímicas e de recursos minerais, disponibilizado no site do Serviço Geológico do Brasil - CPRM.

A composição do Gradiente Total (GT) binária com a Inclinação do Sinal Anômalo (ISA) - MAPA PRINCIPAL - tem como objetivo ressaltar os pontos fortes desses dois filtros. Dentro os filtros citados, o GT apresenta a maior correlação com a geologia de superfície, porém, a perda de resolução com a profundidade é relevante. Como a ISA equilibra as fontes profundas as amplitudes das rotas, esse problema do GT é minimizado. Desta forma, tem-se um produto que representa a distribuição de magnetização rasa, e que também é possível identificar a estruturação profunda. A combinação deste tema com as derivadas verticais permite ao usuário ter uma leitura qualitativa das fontes rasas e profundas.

Os mapas geológicos preditivos (CRACKNELL & READING, 2014; COSTA et al., 2019) - ENCARTE GEOLOGICO PREDITIVO - apresentam resultados para o auxílio do mapeamento geológico utilizando machine learning para acelerar a cartografia geológica. A resolução e qualidade dos resultados cartográficos está diretamente relacionada aos dados de entrada. Foi utilizado como dados de entrada levantamentos aerogeofísicos com 500 m de espaçamento de linhas de voo e interpoladas em grade com tamanho de célula de 125 m. Imagens de sensoramento remoto Landsat 8 das bandas 2 (0,450 - 0,515 µm), 3 (0,520 - 0,600 µm), 4 (0,620 - 0,680 µm), 6 (1,100 - 1,660 µm) e 7 (2,100 - 2,200 µm). Além da cartografia geológica em escala 1:250k, utilizada como 'target' (alvo), a metodologia consiste em separar todos os dados em folhas 1:100k e gerar qualquer diferença de projeção geográfica, bem como representar todas as imagens para a menor resolução dos dados.

Os dados geoquímicos estão disponíveis no Sistema de Geocinética do Serviço Geológico do Brasil (GeoSGB). As amostras de sedimentos de corrente foram coletadas de maneira com pontos e acondicionadas em sacos de pano, secas naturalmente e acondicionadas em sacos de pano. Foram enviadas para análise para 37 elementos por ICP-MS por digestão de água régua, e para Au por fire assay nos laboratórios da ITS - Intertek Testing Services - Bondar Clogg do Brasil.

As amostras de concentrados de minerais pesados foram coletadas de maneira simples a partir de 15 l de material aluvionar, e acondicionadas em sacos plásticos. As amostras foram submetidas à análise mineralógica ótica semiquantitativa e contagem de pontas de ouro nos Laboratórios de Análises Minerais do SGB-CPRM nas superintendências Regionais de Porto Alegre e Recife. Os pontos de destaques mineralométricos foram selecionados por conterem partículas de ouro elevadas.

Os pontos de amostragem geoquímica mostram concentrações destacadas para os elementos Au, Cu, Pb e Zn, onde foram considerados valores de concentração maiores que 75% da população de cada elemento.

O método de extração automática de lineamentos é dividido em duas etapas: (i) análise de textura para realçar as variações magnéticas locais, (ii) detecção de sinema para identificar as descontinuidades magnéticas (HOLDEN et al., 2008). O método é eficiente para detectar zonas de cisalhamento, falhas normais, e limites de domínios magnetométricos. Indica os lineamentos automatizados como um guia à interpretação estrutural. Todavia, a interpretação deve ser feita com cautela, visto que o método tende a segmentar as estruturas regionais, e gerar artefatos curvilíneos. Portanto, recomenda-se a utilização em conjunto com os dados magnetométricos brutos.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser responsabilizados por eventuais incorreções ou omissões contidas no Conteúdo. Da mesma forma, o SGB-CPRM não representa, nem garante, qualquer emprego, aplicação, uso ou resultado empregado e acionista não responderá pelo uso do Conteúdo, e sugere que os usuários utilizem sua própria experiência no tratamento das informações contidas no Conteúdo, ou busquem aconselhamento de profissionais independentes capazes de avaliar as informações contidas no Conteúdo. O Conteúdo não constitui aconselhamento de investimento, financeiro, fiscal ou jurídico, tampouco prevê recomendações relativas a instrumentos de análise geocientífica de investimentos ou eventuais produtos. Por fim, qualquer trabalho, estudo ou análise que utilize o Conteúdo deve fazer a devida referência bibliográfica.

CITACIONES BIBLIOGRÁFICAS: PINTO, et al., 2021.

CHEN, T., & GUERTRIN, C., 2016. XGBocst: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794). New York, NY, USA: ACM. https://doi.org/10.1145/2903672.2903785.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

COSTA, I. S. L., TAVARES, F. M., DE OLIVEIRA, J. K. M., 2019. Predictive lithological mapping through machine learning methods: a case study in the Cuzco Lineament, Cuzco Province, Brazil. Journal of the Geological Survey of Brazil, v. 2, n. 1, p. 20-36, 2019.

CRACKNELL, M. J., READING, A., 2014. Geophysical mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

HOLDEN, E. J., DENNIS, M., KOWAL, P., 2008. Using anomalies detection through Random Forest regression. Exploration Geophysics. https://doi.org/10.1080/0013798X.2008.1725387.

AVISO LEGAL: O conteúdo disponibilizado nesta 'Carta de Anomalias' foi elaborado pelo Serviço Geológico do Brasil - CPRM com base em dados obtidos através de trabalhos próprios e de informações de domínio público. O SGB-CPRM não garante (i) que o Conteúdo atenda ou se adequa às necessidades de todos os usuários, (ii) que o Conteúdo e o acesso a ele estejam totalmente livres de falhas, (iii) a total precisão de quaisquer dados ou informações contidas no Conteúdo, apesar das precauções de praxe tomadas pelo SGB-CPRM. Assim, o SGB-CPRM, seus representantes, dirigentes, prepostos, empregados e acionistas não podem ser