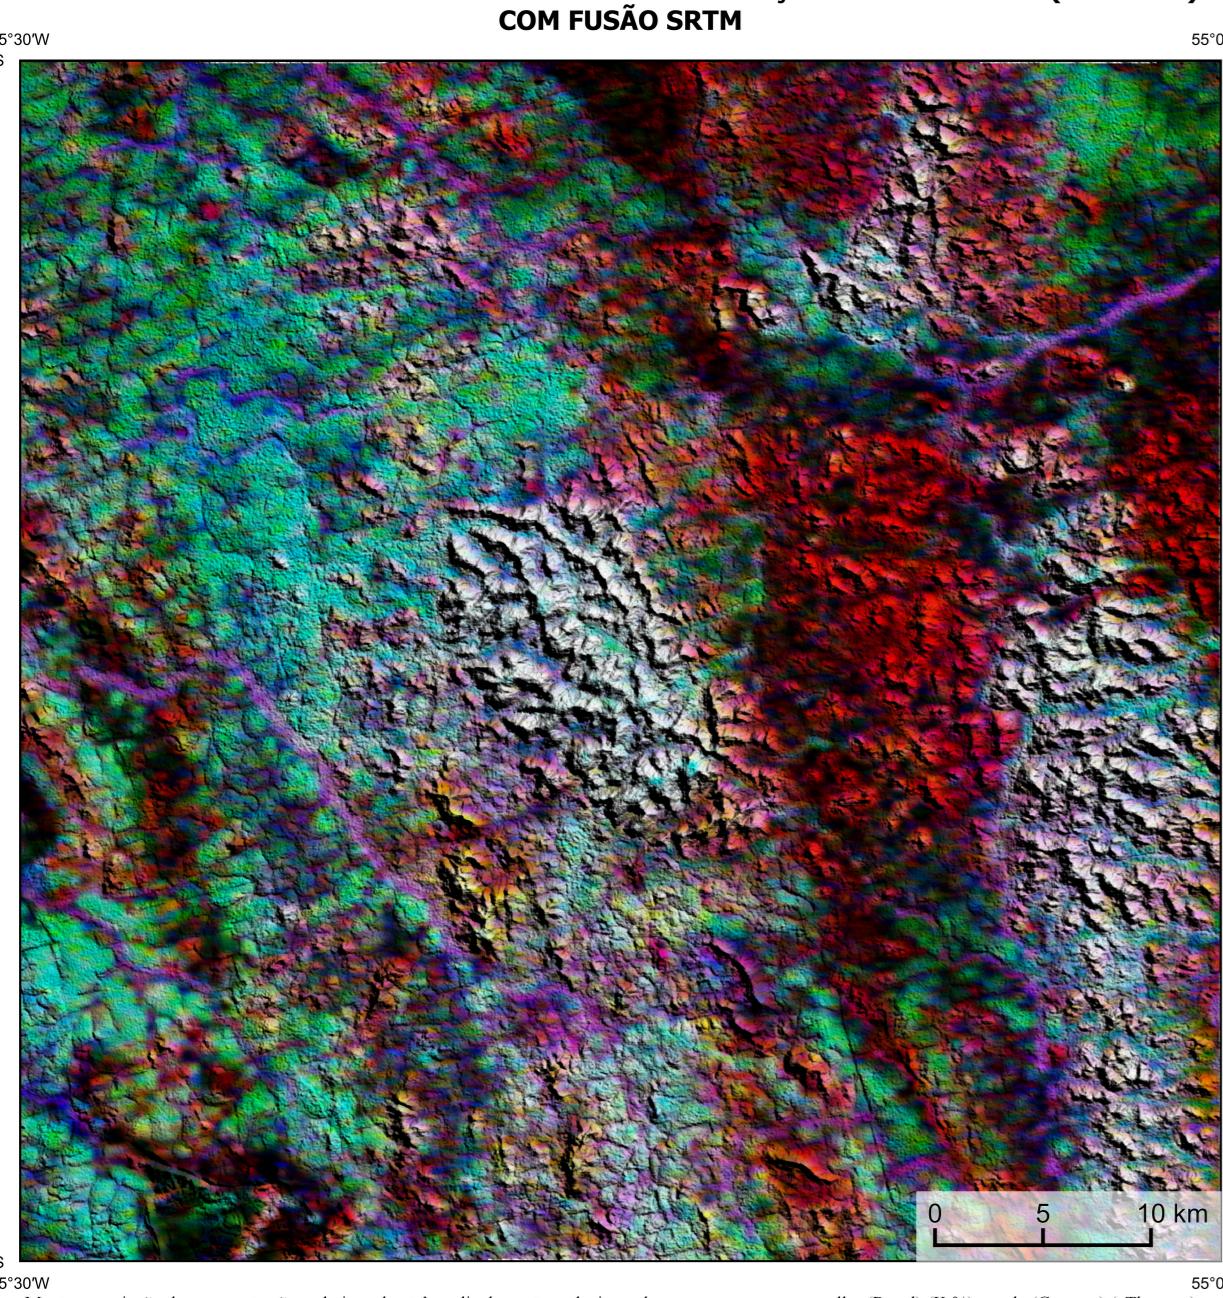
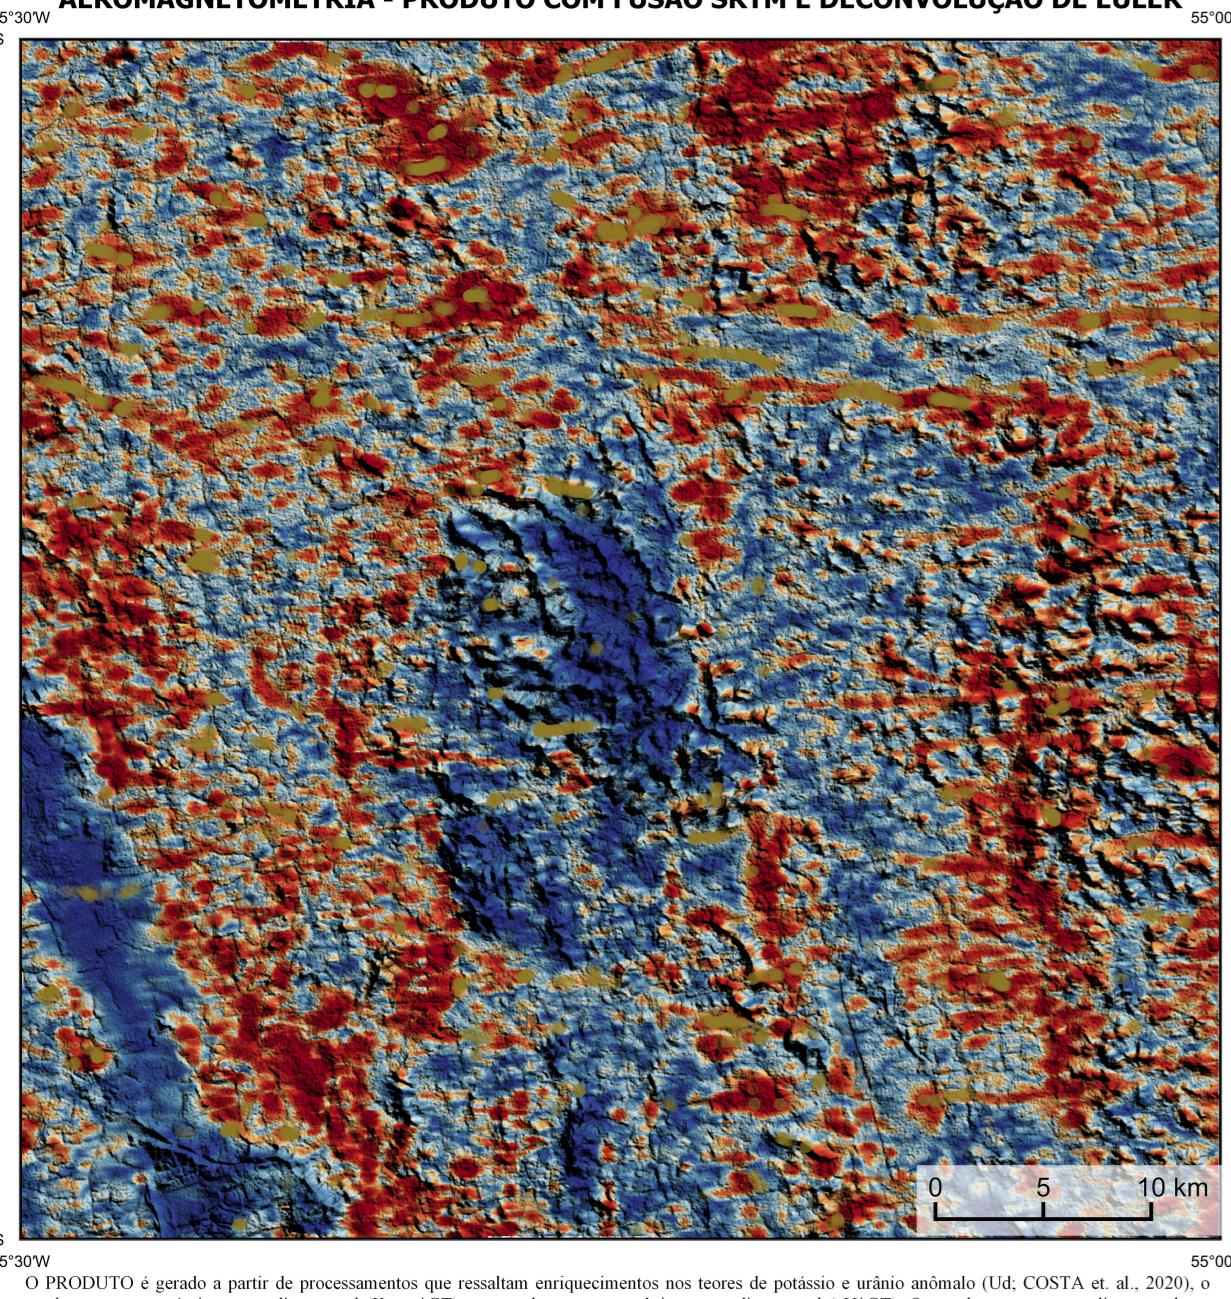


AEROGAMAESPECTROMETRIA - IMAGEM DE COMPOSIÇÃO TERNÁRIA RGB (K-eTh-eU) COM FUSÃO SRTM



AEROMAGNETOMETRIA - PRODUTO COM FUSÃO SRTM E DECONVOLUÇÃO DE EULER



MODELO DIGITAL DO TERRENO E BASE CARTográfICA COM A IDENTIFICAÇÃO DAS ESTAÇÕES GEOQUÍMICAS DE SEDIMENTOS DE CORRENTE (QUANDO EXISTIR)

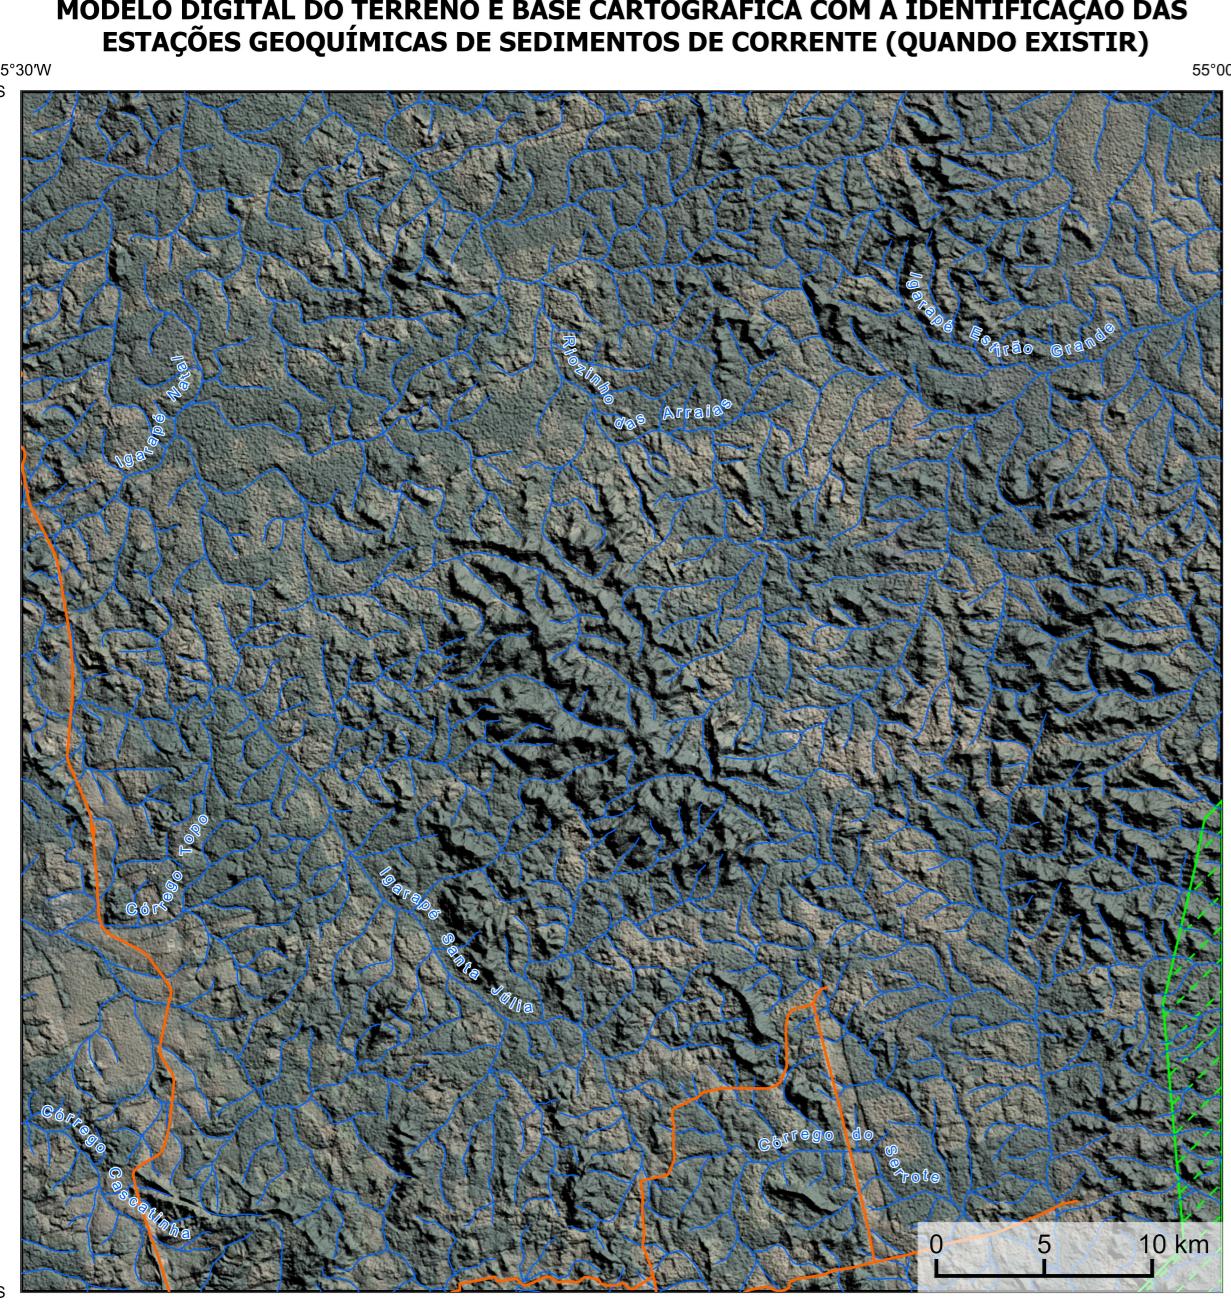
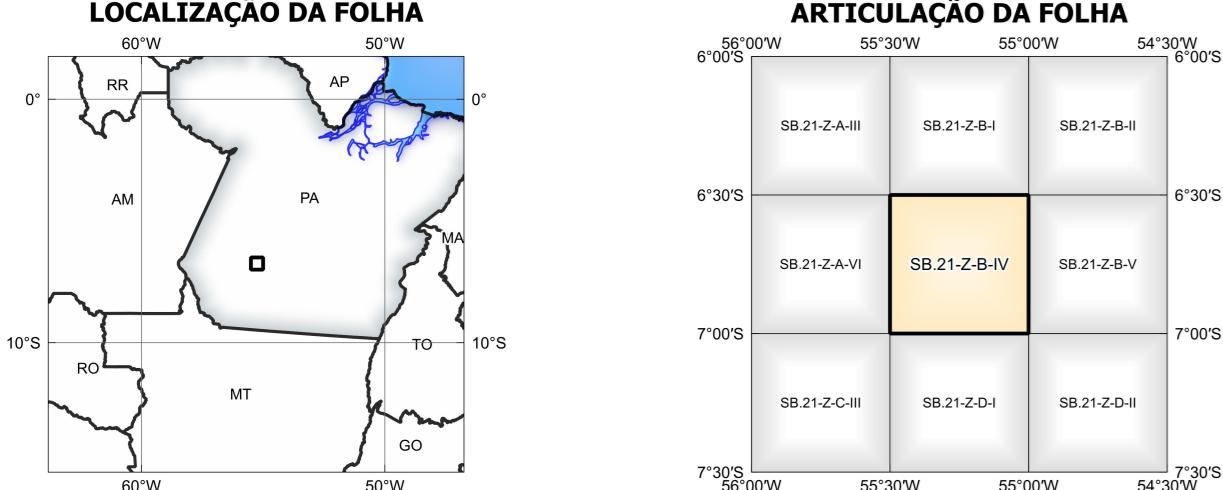
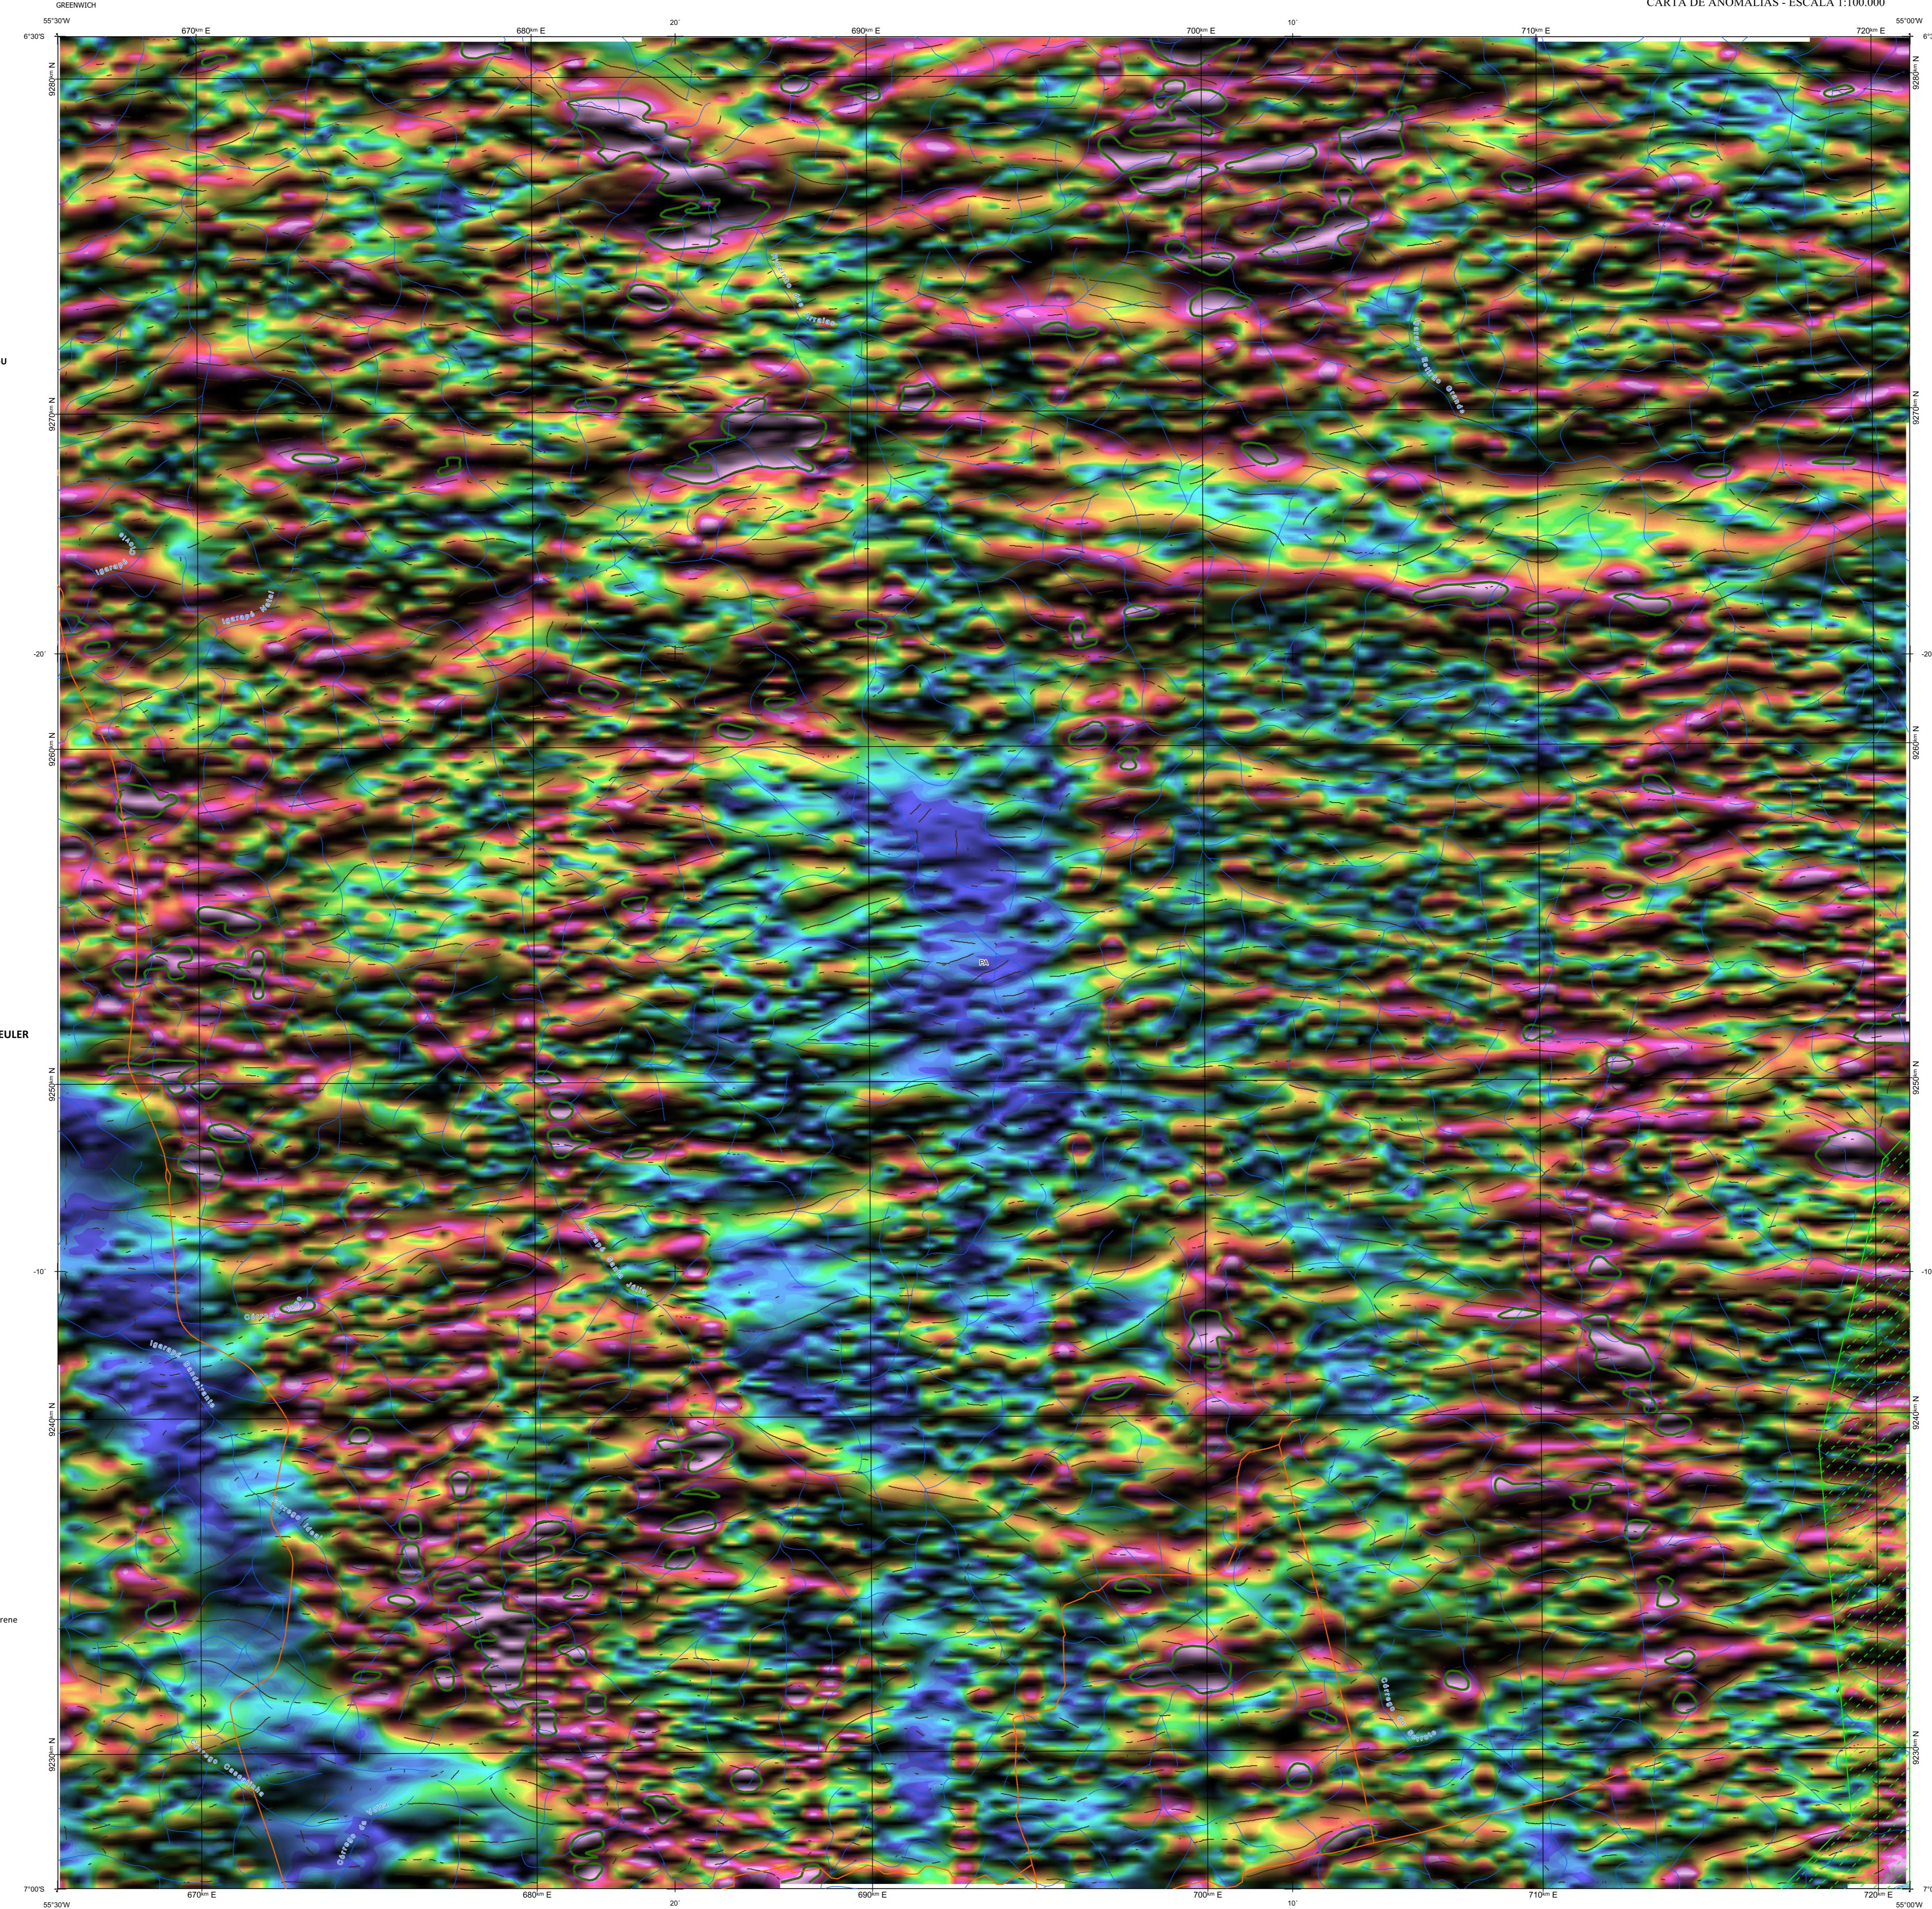


IMAGEM GOOGLE EARTH - JULHO 2022.



FOLHA SB.21-Z-B-IV

GREENWICH



NOTA TÉCNICA

Com objetivo subsidiar informações geocientíficas às iniciativas e projetos de pesquisa mineral do setor privado, o Serviço Geológico do Brasil - CPRM disponibiliza esta carta que visa auxiliar na identificação de possíveis anomalias geofísicas. Esta é uma previsão designada "carta de anomalias" que não deve ser considerada definitiva, que sofreu devido à falta de referência espacial como dados de entrada para modelagem. Além disso, os alvos são selecionados aleatoriamente com base em mapas de baixa resolução (1:250k), ficando com que os dados de treino, validação, e teste sejam altamente contaminados com viés de interpretação.

O método de extração automática de linamentos magnétometrícios é dividido em duas etapas: i) análise de textura para realçar as variações magnéticas locais; ii) detecção de simetria para identificar as discontinuidades magnéticas (HOLDEN *et al.*, 2008). O método é eficiente para detectar zonas de cislamento, falhas rupturadas, e linamentos magnétometrícios. Indica-se os linamentos automáticos como uma guia à interpretação estrutural. Todavia, a interpretação spatial da distribuição de training data e o uso de explicit spatial information. Computers & Geosciences, v. 63, p. 22-33.

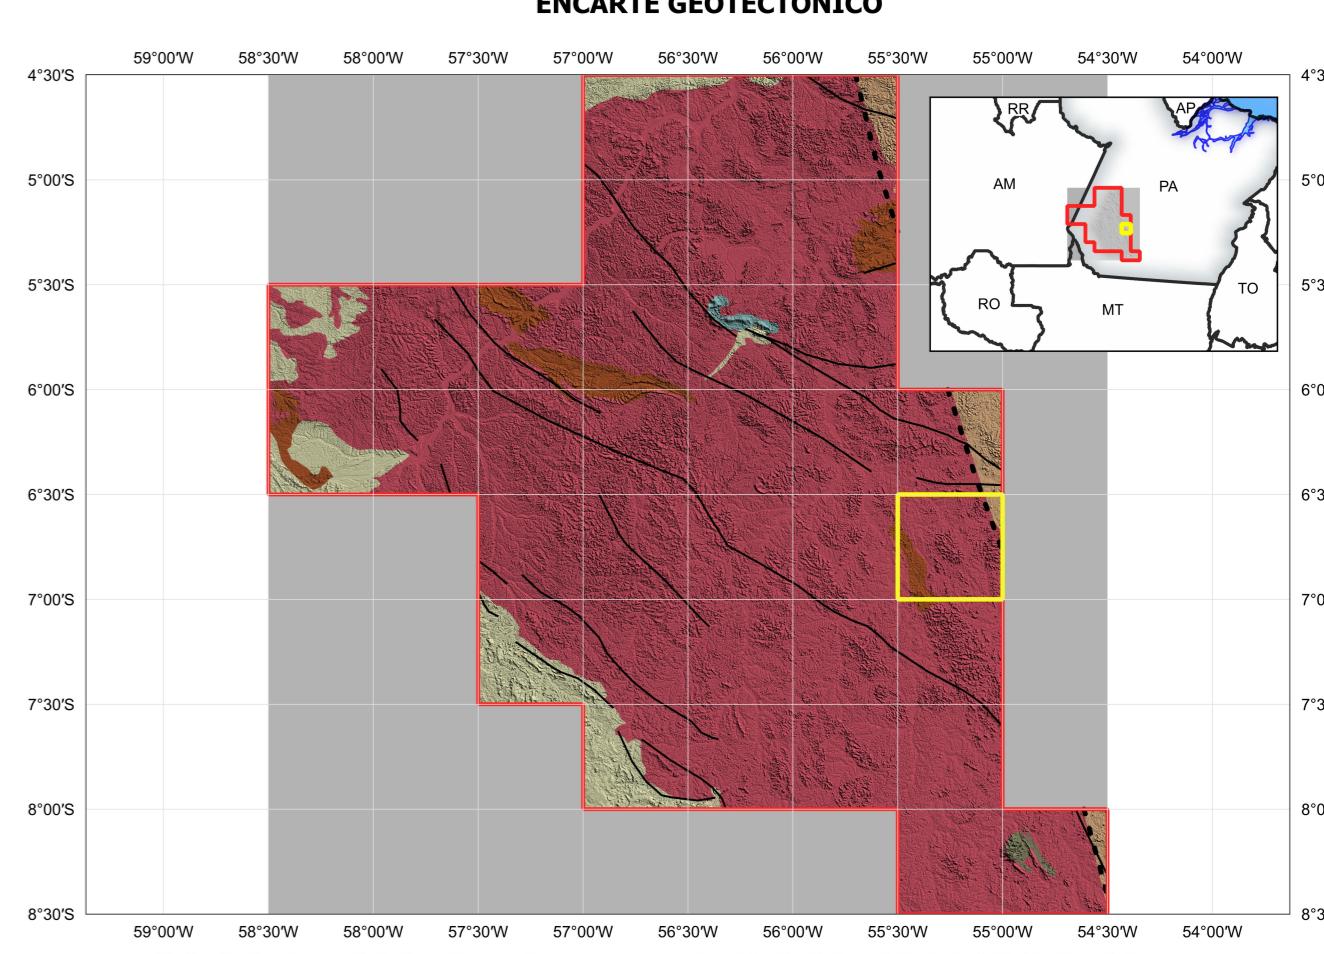
A composição do Gradiente Total (GT) binária com a inclusão do Sinal Analítico (ISA) - MAPA PRINCIPAL - tem como objetivo ressaltar os pontos fortes desse filtro. Dentro dos filtros citados, o GT apresenta a maior correlação com a geofísica; porém, a perda de resolução com a profundidade das amostras pode levar ao problema do GT minimizado. Desta forma, têm-se um produto que é relevante. Como a ISA equilibra as fontes profundas as amplitudes das fontes, o problema do GT é minimizado.

O texto refere-se ao processamento dos dados geoquímicos permanente na nota técnica mesmo quando não existem dados geoquímicos para esta folha. Os dados geoquímicos estão disponíveis no Sistema de Geociências do Serviço Geológico do Brasil (GeoSGB). As amostras de sedimentos de corrente foram coletadas de maneira com posta e acondicionadas em sacos de plástico, sacas, sacos naturalmente e pulverizados. 2009. Foram realizadas amostras de sedimento de corrente-solo e aluviais com profundidade de 0 a 100 m. Linhas de corrente espessas de 10 m na direção leste-oeste complementando as dades. Devido a características químicas que permitem utilizadas na aquisição das dades, tem-se em média, ao longo da linha de uma leitura magnétometrística a cada 8 m e uma leitura geoquímétrica a cada 80 m.

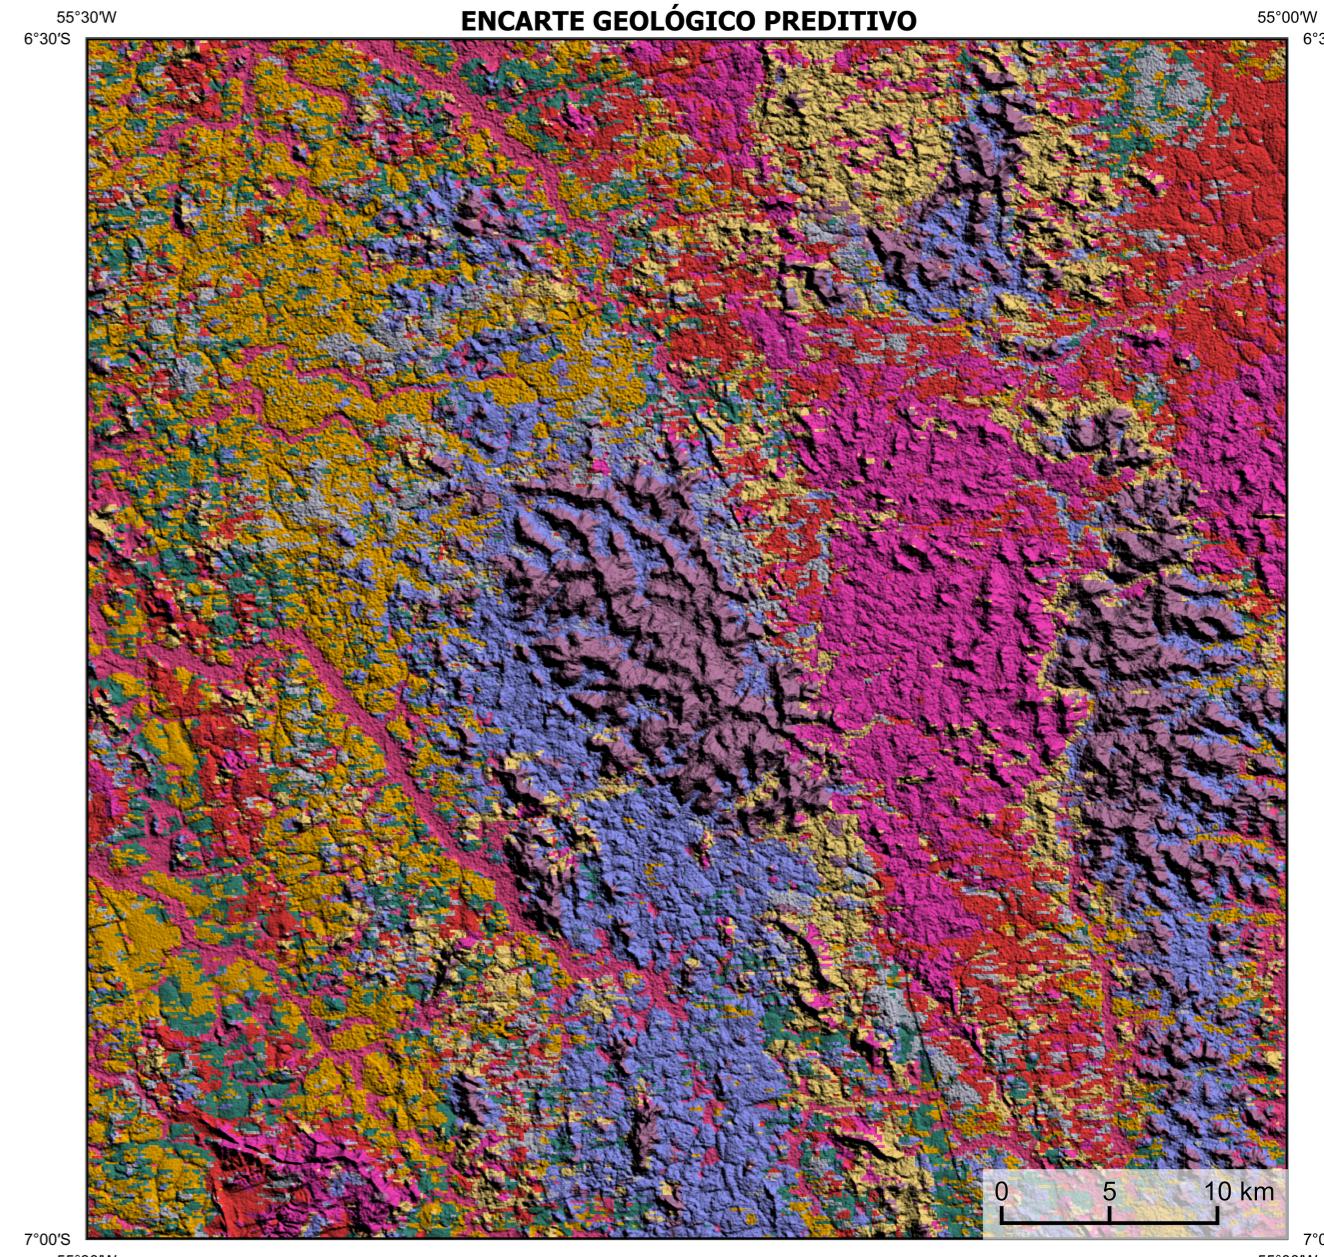
CITAÇÕES BIBLIOGRÁFICAS

- CHEN, T., & GLOSTROM, C. 2010. XGBoost: 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/10.1145/1835802.1835855>.
- COSTA, I. S. L., TAVARES, J. M., DE OLIVEIRA, J. M. 2019. Predictive lithological mapping through machine learning methods: a case study in the Cimenteiro Linear, Brazil. *Journal of the Brazilian Geological Society*, v. 58, n. 1, p. 1-10.
- COSTA, I. S. L., SERAFIM, I. C. C. D. O., TAVARES, S. J. M., POLO, H. J. D. O. 2020. Uranium anomalies detection through Random Forest regression. Exploration and Production in Brazil - CEP. Esse artigo não possui espécie entre as publicações de acesso aberto da UFSCar. Foi feito uma busca no Google Scholar.
- CRACKNELL, M. J., READING, A. 2014. Geological 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, L. J., DANIEL, M., KOEVE, P. 2008. Towards the automated analysis of regional aeromagnetic data to identify regions prospective for gold deposits. *Computer & Geosciences*, v. 34, p. 1089-1101.
- REFFERT, C. R., GLECKLER, C. 2010. XGBoost: 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/10.1145/1835802.1835855>.
- SERAFIM, I. C. C. D. O., TAVARES, J. M., COSTA, I. S. L., POLO, H. J. D. O. 2020. Uranium anomalies detection through Random Forest regression. Exploration and Production in Brazil - CEP. Esse artigo não possui espécie entre as publicações de acesso aberto da UFSCar. Foi feito uma busca no Google Scholar.
- SOARES, M. R. 2019. Análise de linamentos magnétometrícios para a identificação de zonas de cislamento e falhas rupturadas no leste-oeste da Bacia do Rio Tocantins. *Revista Brasileira de Geociências*, v. 49, n. 1, p. 1-10.
- SOARES, M. R. 2020. Análise de linamentos magnétometrícios para a identificação de zonas de cislamento e falhas rupturadas no leste-oeste da Bacia do Rio Tocantins. *Revista Brasileira de Geociências*, v. 50, n. 1, p. 1-10.
- SOARES, M. R. 2021. Análise de linamentos magnétometrícios para a identificação de zonas de cislamento e falhas rupturadas no leste-oeste da Bacia do Rio Tocantins. *Revista Brasileira de Geociências*, v. 51, n. 1, p. 1-10.
- SOARES, M. R. 2022. Análise de linamentos magnétometrícios para a identificação de zonas de cislamento e falhas rupturadas no leste-oeste da Bacia do Rio Tocantins. *Revista Brasileira de Geociências*, v. 52, n. 1, p. 1-10.

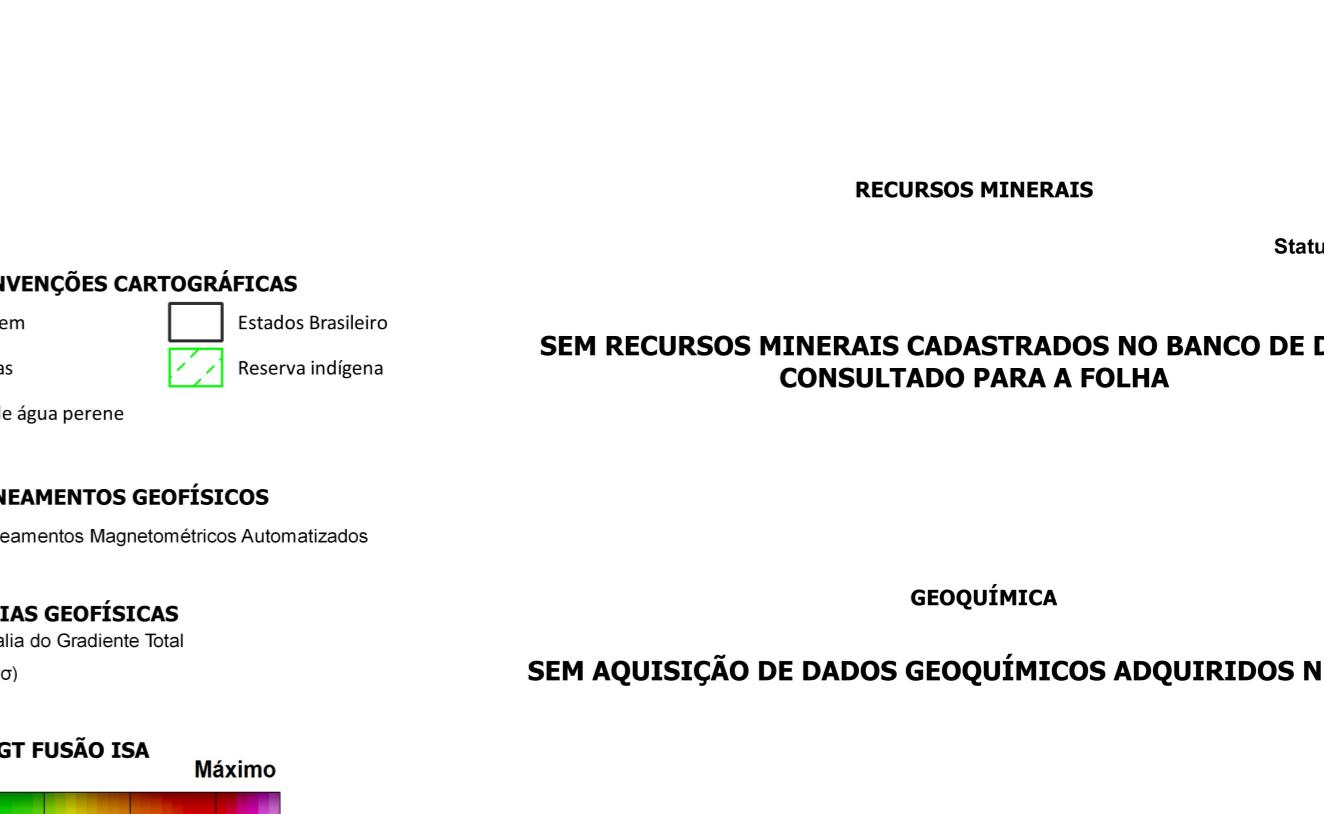
ENCARTE GEOTECTÔNICO



ENCARTE GEOLÓGICO PREDITIVO



RECURSOS MINERAIS



SEM RECURSOS MINERAIS CADASTRADOS NO BANCO DE DADOS CONSULTADO PARA A FOLHA

Status e Classe Genética

CONVENÇÕES CARTOGRAFICAS

Drenagem Estados Brasileiro

Rodovias Reserva Indígena

Curso de água perene

LINEAMENTOS GEOMAGNETICOS AUTOMATIZADOS

ANOMALIAS GEOFÍSICAS Anomalia do Gradiente Total ($\mu + 2\sigma$)

Mínimo GT FUSÃO ISA Máximo

Legendas Geológico Preditivo

Q2a PP3-qp

PP3-qc

PP3-qd

PP3-ml

PP3-qm

PP3-zn

PP3-znq

PP3-qsa

CONTRIBUIÇÃO DE AUTORIA

MINISTÉRIO DE MINAS E ENERGIA Adelio Soledade

SECRETARIA DE GEOLOGIA, MINERAÇÃO E TRANSFORMAÇÃO MINERAL Pedro Paula dos Neves

SERVICO GEOLOGICO DO BRASIL - CPRM

DIRETOR PRESIDENTE Edson Soledade

DIRETORIA DE GEOLOGIA E RECURSOS MINERAIS Marcos José Renedo

DIRETORIA DE HIDROGEOLIA E GESTÃO TERRITORIAL Alice Silveira de Castro

DIRETORIA DE ADMINISTRAÇÃO E FINANÇAS Cassiano de Souza Alves

DIRETORIA DE INFRAESTRUTURA E GEOCIENTIFICA Paulo Afonso Roman

COORDENAÇÃO TÉCNICA NACIONAL

DEPARTAMENTO DE GEOLOGIA Walter Rodrigues Santos Sobrinho

DEPARTAMENTO DE RECURSOS MINERAIS Mariana Estrela Almeida

DIVISÃO DE GEOLOGIA BÁSICA Paolla Aranha dos Santos

DIVISÃO DE GEOPHYSICS Guilherme Ferreira da Silva

DIVISÃO DE SENSOREAMENTO REMOTO E GEOPHYSICS Luiz Gustavo Rodrigues Pinto

DIVISÃO DE GEOPHYSICA Silvana de Carvalho Melo

CRÉDITOS DE AUTORIA

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; FERREIRA, M. A.; PINTO, V. P.; CUNHA, R. T.; LIMA, R. A. P.; RISUS, D.; FERRARI, V. C.; EBERHARDT, R.; AUGUSTO, R.; PEREIRA, D.; SOARES, M. R.; VIANA, C.; FERRAZ, D.; CRACKNELL, M. J.; READING, A. 2014. Geological 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.

PINTO, L. R.; F