

UNIVERSIDADE FEDERAL DO PARANÁ

MATHEUS PEREIRA NOGUEIRA E SILVA

PREDIÇÃO DA PROVENIÊNCIA DE VESTÍGIOS DE SOLO EM AMBIENTE
SUBTROPICAL: APLICAÇÃO DE MÉTODOS GEOESTATÍSTICOS
EM BANCOS DE DADOS

CURITIBA

2021

MATHEUS PEREIRA NOGUEIRA E SILVA

PREDIÇÃO DA PROVENIÊNCIA DE VESTÍGIOS DE SOLO EM AMBIENTE
SUBTROPICAL: APLICAÇÃO DE MÉTODOS GEOESTATÍSTICOS
EM BANCOS DE DADOS

Dissertação apresentada como requisito parcial à
obtenção do grau de Mestre em Geologia, no
Programa de Pós-Graduação em Geologia, Setor
de Ciências da Terra, Universidade Federal do
Paraná

Orientação: Prof. Dr. Carlos Conforti Ferreira
Guedes

CURITIBA

2021

Catalogação na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

S586p Silva, Matheus Pereira Nogueira e

Predição da proveniência de vestígios de solo em ambiente subtropical: aplicação de métodos geoestatísticos em bancos de dados [recurso eletrônico] / Matheus Pereira Nogueira e Silva – Curitiba, 2021.

Dissertação - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Geologia.

Orientação: Prof. Dr. Carlos Conforti Ferreira Guedes

1. Geoestatística. 2. Prática forense. I. Universidade Federal do Paraná. II. Guedes, Carlos Conforti Ferreira. III. Título.

CDD: 551.072

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIENCIAS DA TERRA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO GEOLOGIA -
40001016028P5

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação GEOLOGIA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **MATHEUS PEREIRA NOGUEIRA E SILVA** intitulada: **PREDIÇÃO DA PROVENIÊNCIA DE VESTÍGIOS DE SOLO EM AMBIENTE SUBTROPICAL: APLICAÇÃO DE MÉTODOS GEOESTATÍSTICOS EM BANCOS DE DADOS**, sob orientação do Prof. Dr. CARLOS CONFORTI FERREIRA GUEDES, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 14 de Dezembro de 2021.

Assinatura Eletrônica

16/12/2021 10:10:57.0

CARLOS CONFORTI FERREIRA GUEDES

Presidente da Banca Examinadora

Assinatura Eletrônica

21/12/2021 14:17:32.0

VANDER DE FREITAS MELO

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

16/12/2021 10:16:01.0

ANELIZE MANUELA BAHNIUK RUMBELSPERGER

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Dedico este trabalho a todos(as) os(as) cientistas e peritos(as) criminais brasileiros(as) que resistem diariamente aos desmontes, repressões e negacionismos, colocando a verdade acima de suas convicções pessoais.

AGRADECIMENTOS

Agradeço à minha família, amigos e colegas de profissão pelo apoio e compreensão durante esta jornada. Em especial, ao meu orientador Prof. Dr. Carlos Conforti Ferreira Guedes, pela confiança e amizade, não hesitando em guiar meus caminhos sempre que necessário; e ao Dr. Fábio Augusto da Silva Salvador, por ser um *outlier* da perícia criminal brasileira e sempre acreditar e investir nas futuras gerações.

À Universidade Federal do Paraná, minha segunda casa a qual frequento há quase metade da minha vida, onde cresci como pessoa e profissional, tendo o privilégio de contar com mestres inspiradores.

Ao Programa de Pós-Graduação em Geologia da Universidade Federal do Paraná, pela oportunidade e suporte, sem a qual esta pesquisa não seria possível.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela promoção da pesquisa por meio do financiamento de bolsa estudantil (CAPES/DS).

Ao Laboratório de Estudos Sedimentológicos e Petrologia Sedimentar (LabESed), ao Laboratório de Pesquisas em Geofísica Aplicada (LPGA) e ao Instituto Lamir (iLamir) pelo acolhimento e disponibilização de toda a infraestrutura necessária para realização desta pesquisa.

Ao Setor Técnico-Científico da Superintendência Regional de Polícia Federal no Paraná (SETEC/SR/PF/PR) e seu quadro de peritos de referência nacional, pelo apoio intelectual, técnico e motivacional.

À Polícia Científica do Paraná (PCP) e sua atual Direção, por enxergarem nas Geociências Forenses uma oportunidade para aprimorar a qualidade da perícia criminal paranaense e servir aos seus cidadãos.

RESUMO

A demanda por banco de dados de solos para fins forenses é comum durante casos criminais onde não há amostras para confronto direto com o vestígio questionado. Para isso, diversos autores já detalharam métodos para inferir a origem de amostras de solo, como a aplicação de intervalos de confiança, similaridade estatística ou aprendizagem de máquina. Entretanto, ainda não foi testada a eficiência destes métodos para predizer a origem de solos gerados em clima subtropical úmido, sob moderada pedogênese. A fim de contribuir com esta lacuna, avaliou-se a preeditibilidade de um banco de dados pedológico construído em uma área de 100 km² ao norte da Região Metropolitana de Curitiba (RMC), onde foram coletadas 232 amostras de solo superficial (< 5 cm), 14 amostras para validação e 38 amostras de subsuperfície (horizonte B). Para determinar suas assinaturas físicas, químicas e colorimétricas, as amostras foram submetidas a análise de susceptibilidade magnética, gamaespectrometria, colorimetria, pXRF e ATR-FTIR. Foram escolhidos três métodos de predição: (1) intervalos de confiança (ICs); (2) distâncias Euclidianas n-dimensionais (EDs); e (3) aprendizagem supervisionada (AS). Essa última envolveu a aplicação dos algoritmos de (a) redes neurais, (b) máquinas de vetores de suporte, (c) árvores de decisão, (d) regressão logística, (e) k-vizinhos mais próximos, (f) *gradient boosting* e (g) floresta aleatória. Após as análises estatísticas descritiva, frequentista e multivariada, foram gerados modelos geoestatísticos das 28 variáveis a partir da técnica da krigagem Bayesiana empírica (EBK) com regressão preeditiva, utilizando-se como matrizes explicativas bases cartográficas geológicas e aerogeofísicas, cujos produtos foram utilizados no método preeditivo dos ICs. Já para a técnica das EDs, os valores de dissimilaridade foram interpolados segundo o método do inverso do quadrado da distância (IQD). Observou-se que as variáveis que melhor se destacaram na discriminação das unidades geológicas e com alta correlação em subsuperfície foram a susceptibilidade magnética, brilho e os teores de Fe, Mn, Cu, Ni e grupo dos elementos leves (LE). O método dos ICs predizeram corretamente a origem de 4 de 14 amostras, reduzindo até 97,5% da área original. Já o método das EDs estimou de forma acurada a proveniência de 8 de 14 amostras, excluindo até 63,4% da área. Em termos de algoritmos de AS, redes neurais obtiveram os melhores resultados, onde foram capazes de predizer a unidade geológica de 71% das amostras de validação. Apesar das limitações e erros inerentes às análises não-destrutivas, do forte intemperismo químico e do alto teor de matéria orgânica, foram obtidos resultados satisfatórios de predição de proveniência, o que demonstra que a variabilidade espacial do solo superficial em ambientes subtropicais úmidos é factível de ser compreendida e utilizada como ferramenta forense, desde que os métodos adequados sejam aplicados.

Palavras-chave: Análise forense. Vestígios de solo. Predição de proveniência. Modelagem geoestatística. Aprendizagem supervisionada.

ABSTRACT

When no samples are available for direct comparisons during a criminal investigation, forensic scientists must resort to georeferenced soil databases in order to find the source of a single questioned evidence. To this end, several authors addressed many methods to infer the origin of soil samples, such as establishing search range intervals, defining statistical similarity, or coding machine learning functions. However, little is currently known about the efficiency of these methods when it comes to highly weathered subtropical soils. Therefore, this study attempts to contribute to this subject by evaluating the predictability of a soil database built in a 100 km² area in the Curitiba Metropolitan Region, Brazil, where 232 topsoil (< 5 cm), 14 validation, and 38 subsoil samples (B horizon) were collected. To determine their physical, chemical, and colorimetric features, samples were subjected to magnetic susceptibility analysis, gamma-ray spectrometry, color analysis, pXRF, and ATR-FTIR. Three prediction methods were applied: (1) search range intervals (SR); (2) n-dimensional Euclidean distances (ED); and (3) supervised machine learning (ML), where 7 different algorithms were tested: (a) neural networks, (b) support vector machines, (c) decision trees, (d) logistic regression, (e) k-nearest neighbors, (f) gradient boosting, and (g) random forest. After the descriptive and multivariate statistical analyses, geostatistical models were generated for the 28 obtained variables using the empirical Bayesian kriging (EBK) with regression prediction method, where geological and airborne geophysical data were used as explanatory matrix. For the ED provenancing method, dissimilarity values were calculated and interpolated by applying the inverse distance weighting (IDW) approach. Findings, while preliminary, suggest that magnetic susceptibility, lightness, Fe, Mn, Cu, Ni, and the light elements group (LE) may be the most significant variables to discriminate parent rock and to correlate with subsurface data. The SR method managed to correctly predict the origin of 4 of 14 validation samples, reducing up to 97.5% of the original area. The ED method, on the other hand, accurately estimated the provenance of 8 out of 14 samples, excluding up to 63.4% of the area. In terms of ML algorithms, neural networks achieved the highest scores, where they matched the bedrock of 71% of the samples. Despite the limitations and errors inherent to non-destructive analyses, the intense chemical weathering, and the high organic matter content, overall soil provenancing results were suitable, demonstrating that spatial variability of topsoils developed under humid subtropical environments can be modeled and used in forensic contexts, as long as the right methods are applied.

Keywords: Forensic analysis. Soil evidence. Provenance prediction. Geostatistical modeling. Supervised learning.

LISTA DE FIGURAS

Figura 1 - Diagrama esquemático ilustrando as relações entre amostras questionadas e controle em um caso fechado hipotético. Modificado de Fitzpatrick & Raven (2012). ...	12
Figura 2 - Diagrama esquemático ilustrando diferentes situações que podem ocorrer em um caso aberto, em que não há amostras conhecidas para confronto direto.	13
Figura 3 - Mapa de calor dos casos de homicídio na Região Metropolitana de Curitiba (RMC) no ano de 2018, com indicação da área de estudo (retângulo cinza) e os limites municipais (linhas pretas). Fonte: Centro de Análise, Planejamento e Estatística (CAPE) da Secretaria de Estado de Segurança Pública (SESP).	16
Figura 4 – Caracterização do embasamento e cobertura pedológica da área de estudo. A) Mapa geológico em escala 1:20.000 das Unidades de Terreno elaborado pelo Instituto Água e Terra (IAT) e a Coordenação da Região Metropolitana de Curitiba (COMECA). ...	19
Figura 5 - Ferramentas utilizadas para a coleta das amostras-controle na área de estudo, em uma profundidade de até 5 cm.....	34
Figura 6 - Exemplos de locais onde foram realizadas as coletas de amostras controle (a) e de amostras de validação (questionadas) em pneus (b), ferramentas (c) e sapatos (d).	35
Figura 7 - Mapa dos triângulos de Voronoi classificados segundo as respectivas áreas de abrangência, com indicação dos pontos de coleta das amostras controle. O histograma exibe a distribuição das áreas dos polígonos.....	37
Figura 8 - Fluxograma analítico aplicado nas amostras coletadas em campo. Em azul, as técnicas analíticas adotadas; em branco, os procedimentos para tratamento das subamostras.....	39
Figura 9 – Estrutura dos modelos de aprendizagem supervisionada, elaborados no software Orange 3.3.....	81
Figure 1 - Heatmap displaying the murder rate of the Curitiba Metropolitan Region in 2018.	49
Figure 2 - Geological (A) and pedological map (B) of the study area.....	51

Figure 3 - Hierarchical clustering based on Pearson correlation distance for the retrieved variables.....	60
Figure 4 - Boxplot diagrams illustrating soil property variation in terms of parent rock..	63
Figure 5 - Soil colors chart for the fine (< 63 µm) and the sand fractions (63 µm - 2 mm), grouped by the geological units.....	64
Figure 6 - ATR-FTIR spectra showing the retrieved peaks between the 400 and 1600 cm ⁻¹ interval, stacked by the corresponding geological class.	65
Figure 7 - Scatter plots with linear regression fits and the 95% prediction (light) and confidence (opaque) intervals, showing the relationship between the topsoil (< 5 cm) and the subsoil (B horizon) for the geophysical (MS and gamma-ray spectrometry), geochemical (pXRF) and colorimetric (HSL) parameters.	66
Figure 8 - EBK regression prediction models for the 28 variables in the dataset. Each raster is reclassified into 10 geometric intervals, ranging from the lowest (blue) to highest values (red).	69
Figure 9 - Prediction results for the 2S (A), 7S (B), 8S (C), and the 14S (D) validation samples, when applied the Search Range (SR) method.....	72
Figure 10 - Prediction results for the 12S (A), 3S (B), 14S (C), and the 8S (D) validation samples, when applied the Euclidean distance (ED) method.....	73

LISTA DE TABELAS

Tabela 1 - Levantamento bibliográfico dos intervalos granulométricos e profundidades de amostragem em estudos de caso envolvendo a análise forense de vestígios de solo.	24
Tabela 2 - Levantamento bibliográfico dos trabalhos relacionados à predição de proveniência de vestígios de solo, com informações sobre o método de predição, técnicas analíticas, população amostral, área total, clima local e profundidade de amostragem. Em negrito, o estudo objeto desta dissertação, para fins de comparação. 29
Tabela 3 - Densidade amostral segundo as unidades litoestratigráficas presentes na área de estudo	36
Tabela 4 - Variáveis que mais explicam os modelos preditivos, para cada unidade geológica e pedológica.....	82
Tabela 5 - Performance dos algoritmos de aprendizagem supervisionada, em termos de acurácia e precisão	83
Table 1 - Summary statistics of the datasets, including the quantitative analysis of distribution, variance, error, and range. Results of Shapiro-Wilk and Wilks' Lambda statistical tests are described below, as well as the first two principal components.	57
Table 2 - Cross validation results and measurement errors for the EBK geostatistical models according to each variable.....	70
Table 3 - Overall provenancing scores for the Search Range (SR) and the Euclidean distance (ED) prediction methods, indicating the excluded area rate (in %) for each validation sample, including the number of variables satisfied during the SR function and the ED to nearest sampled neighbor.....	71

SUMÁRIO

1 INTRODUÇÃO.....	12
1.1 Objetivos	14
1.2 Estrutura da dissertação	15
1.3. Caracterização da área de estudo	15
1.3.1 Cenário local da Segurança Pública	15
1.3.2 Contexto geológico regional.....	17
1.3.3 Unidades pedológicas	19
2 FUNDAMENTAÇÃO BIBLIOGRÁFICA	20
2.1 O solo como ferramenta forense.....	20
2.1.1 Histórico, princípios e aplicações	20
2.1.2 Técnicas de coleta e análise	22
2.2 Predição da proveniência de vestígios geológicos.....	27
2.3 Aprendizagem de máquina supervisionado	31
3 MATERIAIS E MÉTODOS	34
3.1 Amostragem.....	34
3.2 Análises não-destrutivas	37
3.2.1 Fluxograma analítico e preparação das amostras	38
3.2.2 Análises radiométricas e de susceptibilidade magnética.....	38
3.2.3 Separação granulométrica e colorimetria	38
3.2.4 Espectroscopia de fluorescência de raios-X portátil (pXRF).....	40
3.2.5 Espectroscopia no infravermelho com transformada de Fourier	40
3.3 Tratamentos estatísticos e geoestatísticos	41
3.4 Modelos de predição de proveniência.....	42

3.4.1	Método dos intervalos de confiança	43
3.4.2	Método das distâncias euclidianas	43
3.4.3	Métodos de aprendizagem supervisionada	43
4	RESULTADOS E DISCUSSÕES.....	44
4.1	Evaluating geostatistical methods along with non-destructive analysis for forensic provenancing organic-rich soils in humid subtropical climate	45
4.2	Resultados Complementares	81
5	CONSIDERAÇÕES FINAIS.....	85
6	REFERÊNCIAS	86
7	APÊNDICE 1.....	107

1. INTRODUÇÃO

Não é recente o interesse de agentes da Justiça acerca da presença de solo em um fato criminoso a ser investigado. Dos antigos relatos de soldados romanos localizando acampamentos inimigos por meio das pedras presas nos cascos de cavalos (Murray, 2004a; Ruffell & Donnelly, 2016) até a análise da ressonância magnética de núcleos atômicos em vestígios de solo encontrados aderidos em superfícies (Hsieh, 2020), o objetivo é o mesmo: estabelecer relações entre amostras – sejam seres vivos, objetos, meios de transporte ou locais (Barone & Di Maggio, 2017).

Quando um vestígio de solo é integrado a uma investigação policial, duas abordagens distintas podem ser seguidas, de acordo com a estrutura e dinâmica do conjunto de provas colhidas ao longo do processo (Ruffell & McKinley, 2008). A situação mais favorável ocorre nas ocasiões em que é possível definir tanto os agentes envolvidos quanto os espaços físicos relacionados com o evento em questão – esta disposição, denominada caso fechado (Figura 1), permite o confronto direto entre amostras questionadas e controles, onde é estabelecido o grau de compatibilidade entre as mesmas (R. W. Fitzpatrick, 2013).

Caso fechado

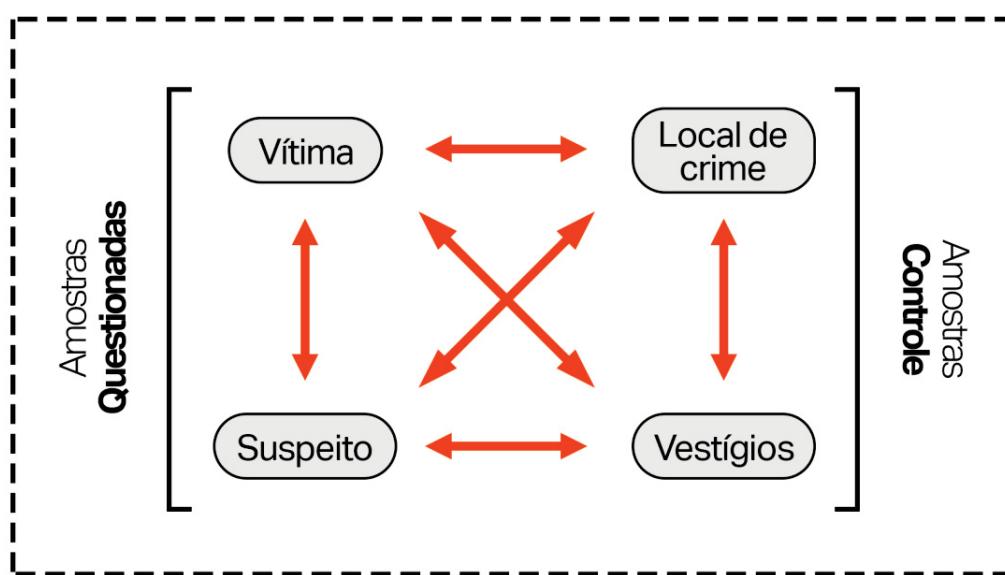


Figura 1 - Diagrama esquemático ilustrando as relações entre amostras questionadas e controle em um caso fechado hipotético. Modificado de Fitzpatrick & Raven (2012).

Os elementos que compõem um caso fechado podem ser as amostras coletadas em vítimas, suspeitos, local de crime, álibis e outros vestígios que estejam correlacionados com o episódio (Ruffell *et al.*, 2013). Todavia, nem sempre os investigadores dispõem destes itens para comparação. Em muitos casos, é comum que se tenha em mãos, isoladamente, apenas amostras coletadas em objetos, vestes ou veículos do suspeito ou da vítima (Aberle, 2017; Bowen & Caven, 2013). Estes são chamados de casos abertos (Figura 2) e suas circunstâncias podem ser resolvidas por meio da utilização de bancos de dados (McKinley, 2013; Rendle, 2004). Em muitas subáreas das Ciências Forenses, estas bases já estão estabelecidas e fornecem excelentes resultados. A exemplo no Brasil, pode-se citar o Banco Nacional de Perfis Genéticos (BNPG), o Banco Nacional de Perfis Balísticos (BNPB) e o Banco Nacional de Perfis Auríferos (BANPA) (Bittencourt & Iwamura, 2019; da Silva Junior *et al.*, 2019).

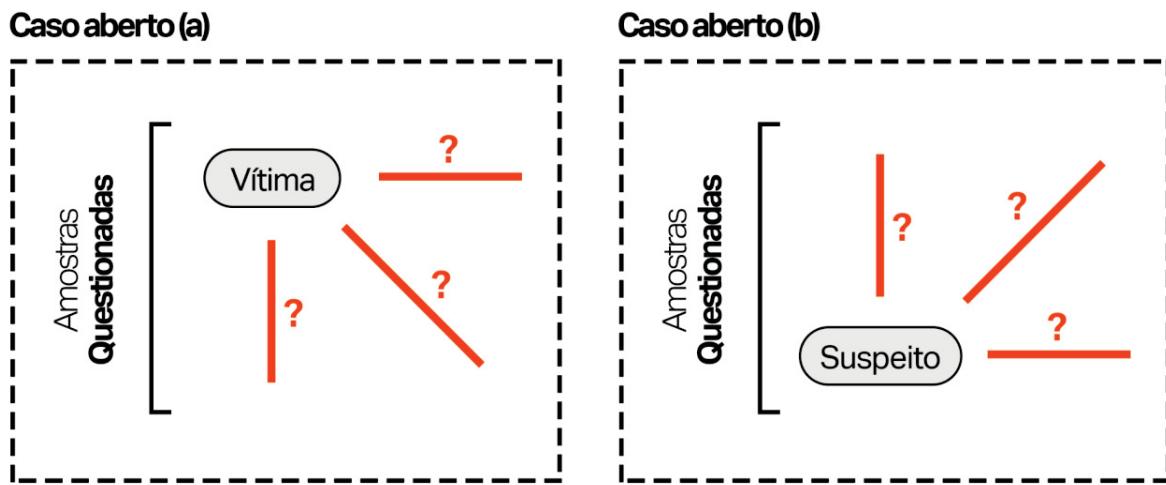


Figura 2 - Diagrama esquemático ilustrando diferentes situações que podem ocorrer em um caso aberto, em que não há amostras conhecidas para confronto direto.

Em relação a banco de dados pedológico para fins forenses, diversos autores já detalharam métodos de atribuição de proveniência para vestígios de solo questionados, tanto utilizando-se bases cartográficas governamentais (Aberle, 2017; Bowen & Caven, 2013; de Caritat *et al.*, 2019; Lark & Rawlins, 2008; McKinley, 2013; Nakai *et al.*, 2014; Pirrie *et al.*, 2017; Rawlins *et al.*, 2006; Rawlins & Cave, 2004; Stern *et al.*, 2019; Tighe *et al.*, 2018), quanto construindo o próprio banco, com amostras superficiais (0 – 5 cm) coletadas e analisadas com este propósito específico (de Caritat *et al.*, 2021; Menchaca

et al., 2018). Estes últimos, no entanto, foram elaborados em regiões de clima mediterrâneo de verão quente (Csa) e clima temperado oceânico de verão ameno (Cwb), respectivamente. Além disso, enquanto o primeiro tipo não abrangeu análises compostionais, o segundo aplicou técnicas destrutivas e de alto custo (análise detalhada na Seção II - Fundamentação Bibliográfica).

Portanto, até então, nenhum avanço foi estabelecido no sentido de compreender o potencial preditivo de bancos de dados de solos formados em ambientes subtropicais úmidos (Cfb), sob moderado intemperismo, e com o emprego de técnicas de análise compostional não-destrutivas. No contexto criminalístico, é de suma importância a preservação de amostras mesmo após a conclusão do exame pericial, uma vez que o Poder Judiciário pode solicitar a realização de novas análises ou repetição do exame, com acompanhamento das partes. Logo, deve-se priorizar métodos não-destrutivos ou aqueles que consomem uma alíquota muito pequena de material. Neste trabalho, pretende-se contribuir com este tópico por meio da construção de um banco pedológico forense e avaliação quanto a sua capacidade de fornecer informações a respeito da origem de materiais questionados inseridos para confronto.

1.1 Objetivos

Este trabalho tem como objetivo geral avaliar o potencial preditivo de um banco de dados de solo subtropical construído a partir de técnicas analíticas não-destrutivas, a fim de auxiliar forças da Segurança Pública em casos abertos nos quais não seja possível realizar um confronto direto entre vestígios de solo.

Por sua vez, os objetivos secundários envolvem:

- (a) Construir um banco de dados de solo contendo informações sobre propriedades radiométricas, magnéticas, geoquímicas e colorimétricas;
- (b) Avaliar métodos de predição de proveniência por (I) intervalos de confiança; (II) distância euclidiana; e (III) algoritmos de aprendizagem supervisionada, com base em amostras cegas de validação.

1.2 Estrutura da dissertação

A dissertação está estruturada em 5 capítulos. No Capítulo 1, referente à Introdução, são apresentados os contextos em que a pesquisa está inserida, assim como os objetivos a serem alcançados, a justificativa e a área de estudo escolhida. No Capítulo 2, são estabelecidos os fundamentos bibliográficos em que serão discutidos os avanços tanto na análise de solos para fins forenses quanto no estudo da proveniência geográfica desse tipo de vestígio. No Capítulo 3, por sua vez, denominado Materiais e Métodos, são descritos todos os procedimentos adotados durante a coleta, análise e tratamento dos dados. Já para o Capítulo 4, Resultados, é exibido na forma do artigo científico intitulado *“Evaluating geostatistical methods along with non-destructive analysis for forensic provenancing organic-rich soils in humid subtropical climate”*. Além disso, apresenta-se também os resultados de predição obtidos por técnicas de aprendizagem supervisionada.

Os últimos capítulos, 5, 6 e 7, referem-se, respectivamente, às Considerações Finais, onde serão abordadas as contribuições deste trabalho e o que pode ser recomendado para pesquisas futuras; as Referências Bibliográficas; e Apêndice 1, com a disposição dos dados brutos coletados em laboratório.

1.3. Caracterização da área de estudo

A região selecionada para o projeto comprehende uma área de 100 km² na Região Metropolitana de Curitiba, entre os municípios de Almirante Tamandaré (PR) e Colombo (PR). O critério para escolha deste perímetro teve como base as seguintes condições: (a) alta variabilidade de domínios geológicos e pedológicos; (b) pouca urbanização; e (c) altos índices de homicídio.

1.3.1. Cenário local da Segurança Pública

O município de Almirante Tamandaré (PR) esteve na 10^a colocação do *ranking* das cidades mais violentas no país com mais de 100 mil habitantes, segundo o Atlas da Violência publicado em 2018 (com dados de 2016) pelo Instituto de Pesquisa Econômica Aplicada (IPEA, 2018), com uma taxa de 88,5 homicídios e mortes violentas com causa

indeterminada (MVCI). No mesmo relatório, a cidade vizinha, Colombo (PR), apresentou uma taxa de 54,5, posicionando-se na 81^a posição – apesar de já ter sido considerado o município mais violento da Região Metropolitana de Curitiba (RMC) em anos anteriores, segundo dados da Secretaria de Estado de Segurança Pública (Sesp) do Paraná.

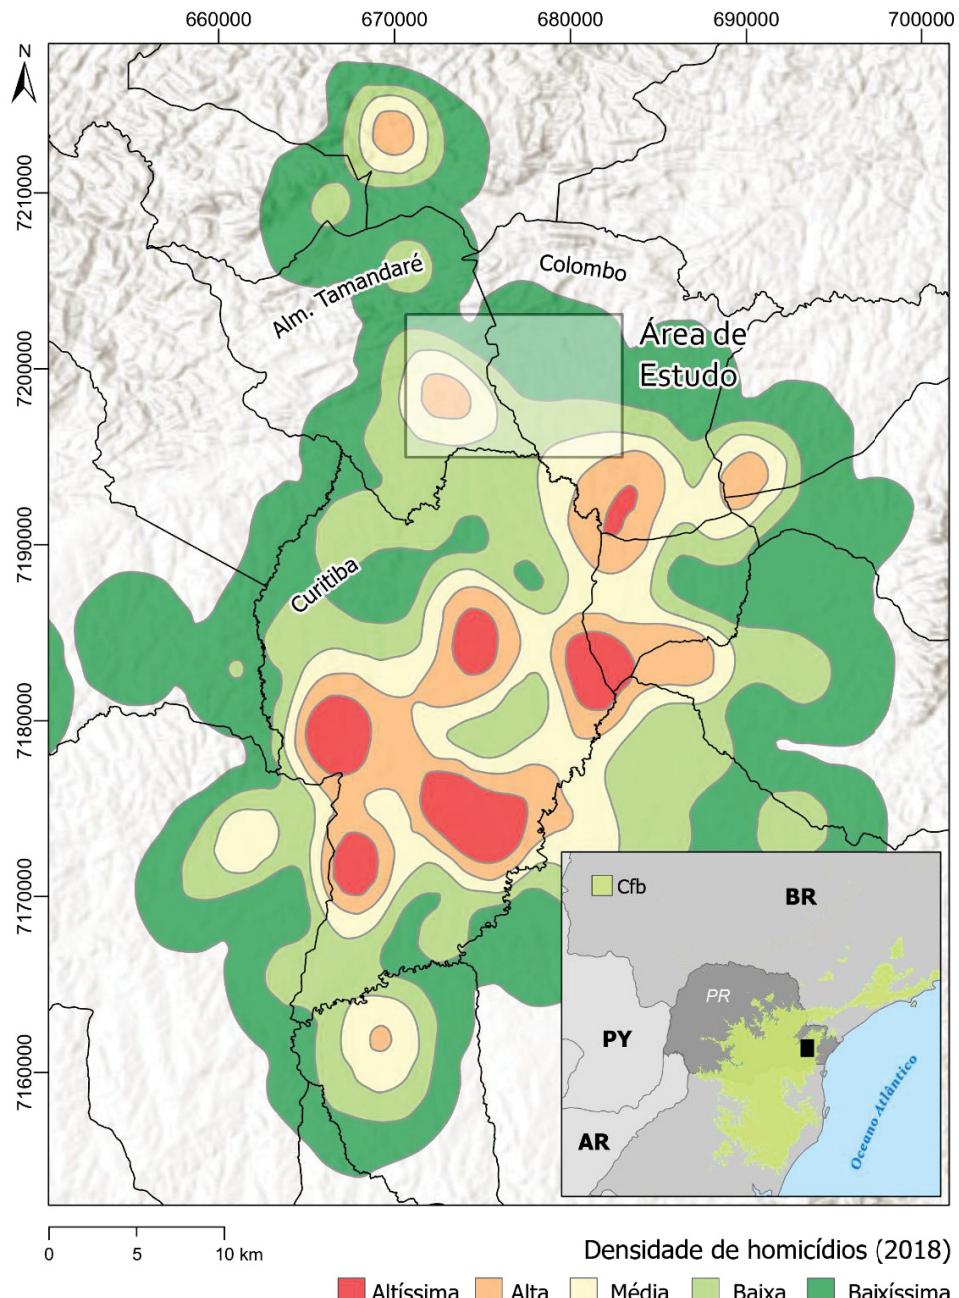


Figura 3 - Mapa de calor dos casos de homicídio na Região Metropolitana de Curitiba (RMC) no ano de 2018, com indicação da área de estudo (retângulo cinza) e os limites municipais (linhas pretas). Fonte: Centro de Análise, Planejamento e Estatística (CAPE) da Secretaria de Estado de Segurança Pública (SESP). Em verde, no canto inferior direito, a região de abrangência do clima subtropical úmido (Cfb).

Apesar da relativa redução de criminalidade indicada pela publicação mais recente do Atlas da Violência de Municípios em 2019 (com dados de 2017), em que Almirante Tamandaré (PR) e Colombo (PR) alcançaram taxas equivalentes a 41,6 e 41,1, respectivamente, a violência ainda faz parte do cotidiano da população local. Além disso, devido às extensas áreas rurais afastadas dos aglomerados urbanos, o interior destes municípios se tornam ambientes propícios para a ocultação de cadáveres, o que ocorre com relativa grande frequência (Figura 3).

1.3.2. Contexto geológico regional

Em termos geológicos (Figura 4a), a área está inserida no contexto da porção meridional do Cinturão Ribeira (Almeida *et al.*, 1973) da Província Mantiqueira (de Almeida *et al.*, 1981), a qual compreende um conjunto de cavalgamentos, dobramentos e transcorrências na direção NNE-SSW de idades meso a neoproterozoicas, relacionadas aos Sistemas de Orógenos Brasilianos. É neste cenário que está inserido o Terreno Curitiba (Heilbron *et al.*, 2008), limitado ao norte pelo Terreno Apiaí, por meio da Zona de Cisalhamento da Lancinha (Fiori & Gaspar, 1993), e ao sul pelo Terreno Luís Alves, abrigando o Complexo Atuba (Salamuni *et al.*, 2003), seu embasamento, e o Supergrupo Açuengui (Campanha & Sadowski, 1999), ambos predominantes na área de estudo.

O embasamento do Terreno Curitiba é formado pelo Complexo Atuba (Siga Junior *et al.*, 1995), onde afloram sequências gnaissicas-migmatíticas paleoproterozoicas, como biotita-hornblenda-gnaisses fácies anfibolito com leucossomas granodioríticos, além de metabasitos, xistos subordinados e corpos graníticos anatéticos.

Já o Supergrupo Açuengui, do Proterozoico Superior, reúne unidades metassedimentares de direção NE-SW, subdividido em três formações: Setuva, Capiru e Votuverava, da base para o topo (Santos *et al.*, 2021). A Fm. Capiru, presente na região designada deste trabalho, comprehende intercalações de mármore, quartzitos e filitos de grau metamórfico incipiente a baixo, formados em paleoambientes marinhos plataformais, leques deltaicos e intermaré (Guimaraes *et al.*, 2002), sendo agrupados estratigráficamente nos conjuntos Juruqui, Rio Branco e Morro Grande (Fiori & Gaspar, 1993).

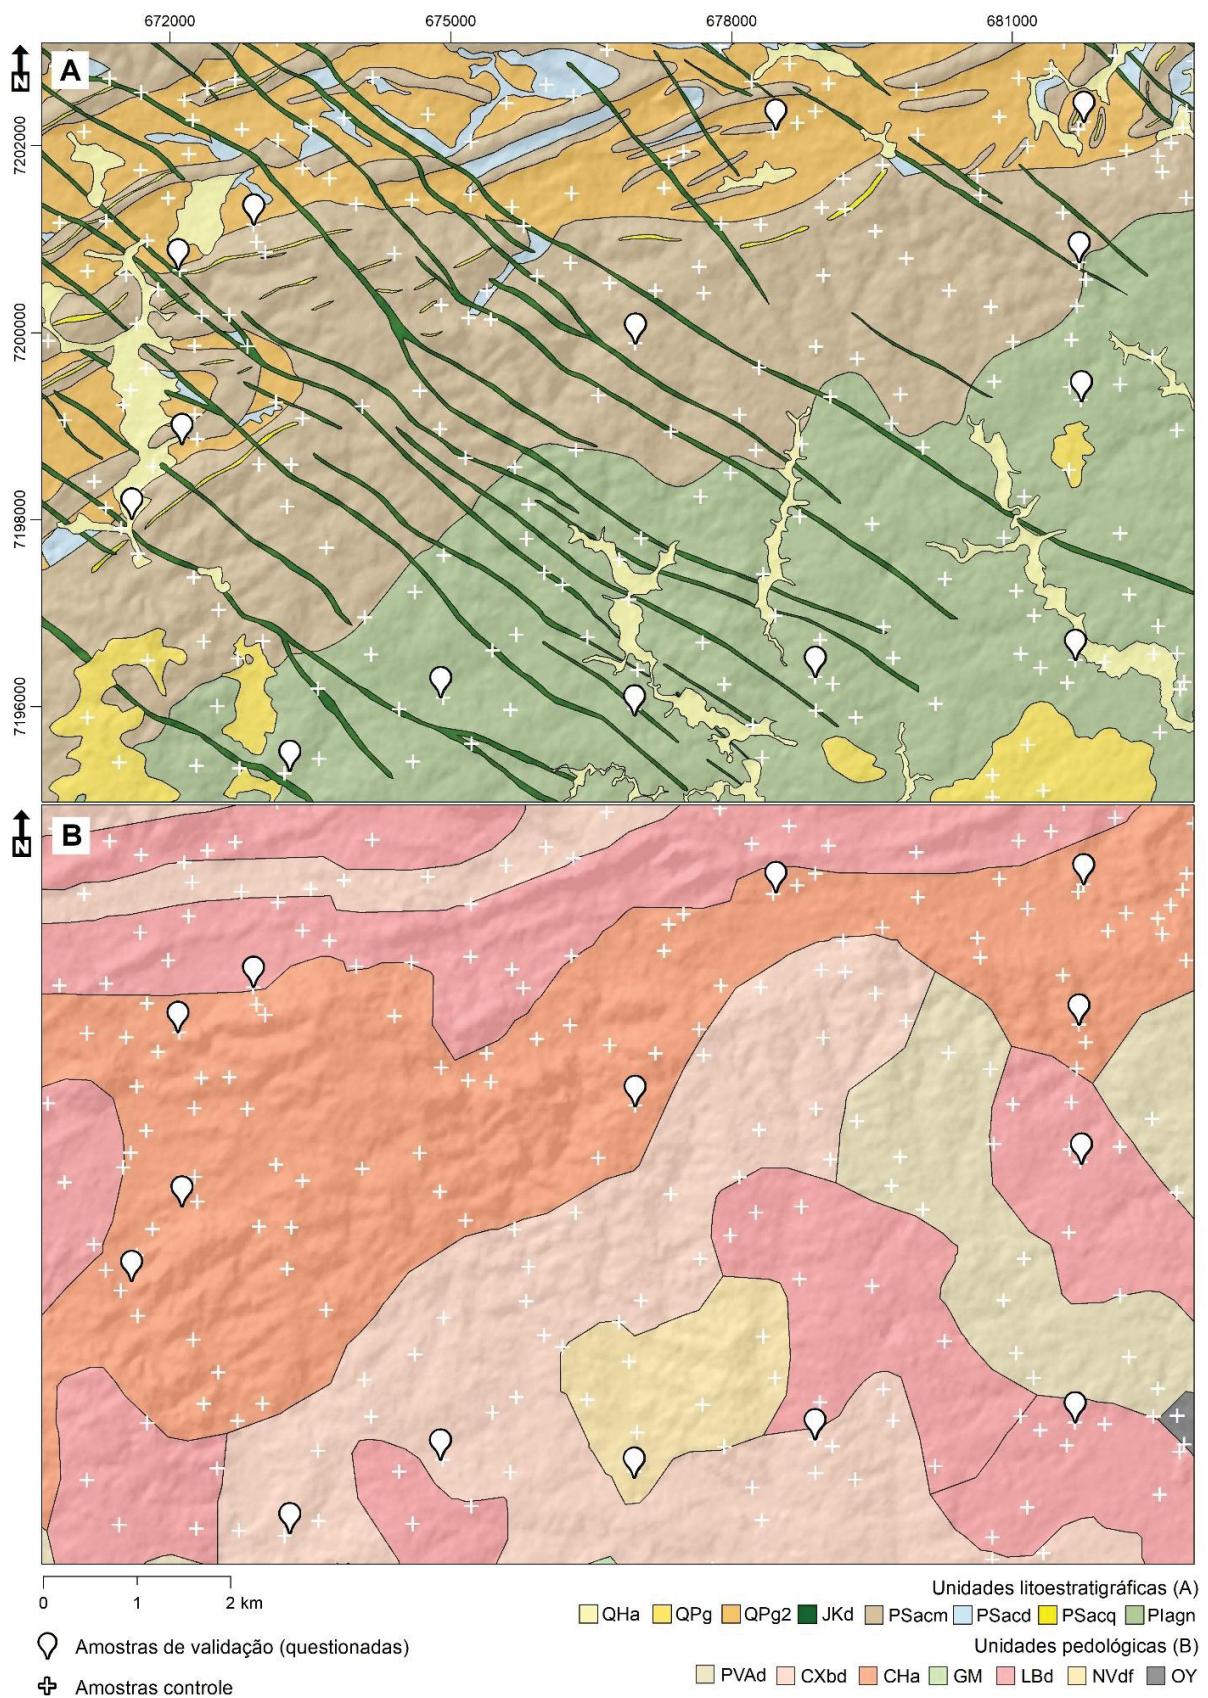


Figura 4 – Caracterização do embasamento e cobertura pedológica da área de estudo. A) Mapa geológico em escala 1:20.000 das Unidades de Terreno elaborado pelo Instituto Água e Terra (IAT) e a Coordenação da Região Metropolitana de Curitiba (COMECA). Qha: sedimentos recentes; QPg e QPg2: sedimentos da Bacia de Curitiba; JKd: Província Magmática do Paraná (PMP); Psacm, PSacd e PSacq: filitos, dolomitos e quartzitos do Supergrupo Açu-Guaíba; Piagn: Complexo Gnáissico-Migmatítico Atuba. B) Mapa de solos do Paraná em escala 1:50.000 produzido pela EMBRAPA/EMATER. PVAd: argissolos vermelho-amarelos distróficos; CXbd: cambissolos háplicos Tb distróficos; CHa: cambissolos húmicos alumínicos; GM: gleissolos melânicos indiscriminados; LBd: latossolos brunos distróficos; NVdf: nitossolos vermelhos distróféricos; OY: organossolos mésicos.

A Província Magmática do Paraná-Etendeka (PMPE), por sua vez, é uma Província Continental Basáltica (PCB) de idade eocretácea (135 – 131 Ma) (Thiede & Vasconcelos, 2010) que se estende por 1,5 milhões de km² na Argentina, Uruguai, Paraguai e centro-sul do Brasil, relacionada com os eventos de abertura do oceano Atlântico sul (Milani & de Wit, 2008). De forma associada, estão os enxames de diques de diabásio de direção NW-SE, com alta penetratividade na área de estudo.

A Bacia de Curitiba, sobreposta ao embasamento pré-cambriano do Terreno Curitiba (Vieira & Fernandes, 2020), integra o conjunto de bacias sedimentares cenozoicas associadas aos Sistemas de Rifts Continentais do Sudeste do Brasil (RCSB), cujos grábens de direção NE-SW propiciaram suas deposições (Salamuni *et al.*, 2003). A Formação Guabirotuba, unidade paleógena que preenche a bacia, é descrita como intercalações de cascalhos, argilas, areias e calcretes, formados em leques aluvionares de clima semiárido (de Lima *et al.*, 2013).

1.3.3. Unidades pedológicas

Em termos de taxonomia pedológica (Embrapa, 2013), afloram na região (Figura 4b) Cambissolos Húmicos Alumínicos típicos de textura argilosa (CHa), ou seja, ricos em matéria orgânica, com teores elevados de alumínio trocável e baixa atividade da argila, inferior a 20 cmolc/kg, e também Cambissolos Háplicos Tb Distróficos (CXbd), com baixa atividade de argila e menores quantidades de matéria orgânica, próprios de relevos suave ondulados. Estes últimos também ocorrem associados, no extremo norte da área, com Neossolos Litólicos Distróficos típicos, os quais compreendem solos rasos em relevos montanhosos e de baixa fertilidade.

Os Latossolos Brunos Distróficos (LBd) estão presentes em 4 categorias: (a) típicos e (b) câmbicos de fase floresta, ambos com A proeminente, textura argilosa e de

relevo ondulado; (c) em associação com Cambissolo Háplico Tb Distrófico (CXbd); e (d) câmbico de fase campo.

São encontrados também Argissolos Vermelho-Amarelo Distrófico típico (PVAd), com teores médios a altos de matéria orgânica, textura argilosa ($> 35\%$ de argila no horizonte B) e situados em declives, de relevo forte ondulado.

Em menores quantidades, estão Nitossolos Vermelhos Distroférricos típicos (NVdf), com altos teores de ferro nos horizontes superficiais, comumente associados com rochas básicas e ultrabásicas, com pouca diferenciação entre horizontes, médios a altos teores de matéria orgânica e textura bastante argilosa.

Organossolos Mésicos Sápicos típicos (OY) e Gleissolos Melânicos indiscriminados (GM) estão presentes de forma incipiente. Os primeiros com altos teores de matéria orgânica, predominantes em várzeas de relevo plano; e os segundos com alta CTC, horizonte A escuro e espesso, rico em matéria orgânica.

2. FUNDAMENTAÇÃO BIBLIOGRÁFICA

2.1 O solo como ferramenta forense

2.1.1 Histórico, princípios e aplicações

As primeiras aplicações modernas do estudo de materiais geológicos em casos criminais datam desde meados do século XIX e início do século XX, quando cientistas descreviam e comparavam, de forma empírica, amostras de solo ou sedimento coletadas por órgãos policiais (Anon, 1856; Gross, 1893; R. C. Murray, 2004b). No entanto, é a partir do início deste século que as Geociências Forenses começam a se estabelecer como uma ciência centralizada, unificada e com desenvolvimento sistemático, principalmente na linha de pesquisa de solos e outros microvestígios associados (L. Donnelly, 2011; R. W. Fitzpatrick & Donnelly, 2021), com grande colaboração internacional (di Maggio *et al.*, 2017).

A partir de princípios e ferramentas da Geologia Clássica, diversos autores já auxiliaram equipes de investigação em casos de homicídios (Brown *et al.*, 2002; Bull *et al.*, 2006; Cocking *et al.*, 2020; Concheri *et al.*, 2011; L. J. Donnelly *et al.*, 2019; R. Fitzpatrick *et al.*, 2017; R. W. Fitzpatrick & Raven, 2012; Melo *et al.*, 2019; K. R. Murray

et al., 2016; Petraco *et al.*, 2008; Reidy *et al.*, 2013; Smale & Trueman, 1969; Szelecz *et al.*, 2018; Testoni *et al.*, 2020), furtos (P. E. de Oliveira & Suguio, 2005; Salvador *et al.*, 2019; Testoni, Melo, Dawson, Salvador, *et al.*, 2019), acidentes de trânsito com omissão de socorro (Fitzpatrick *et al.*, 2009), exumação cadavérica (McPhee, 1996), estupro (Horrocks & Walsh, 1999; Kasu & Shires, 2015; Stella *et al.*, 2020), crimes contra a fauna (Coimbra & Coutinho, 1976) e outras situações.

Considerado um dos pilares da Ciência Forense, o Princípio da Transferência de Locard (Locard, 1920) estabelece que inexiste uma ação que não resulte em troca de vestígios, ou seja, toda interação entre indivíduos e ambientes promove a modificação de seus estados originais, em um sistema aberto - bastando, portanto, o emprego de técnicas sensíveis o suficiente para detectar essa transferência de matéria ou energia. Baseado neste princípio, Aardahl (2003) sugeriu que o vestígio ideal deve atender a estas 7 propriedades: (1) ser pouco visível, o suficiente para não ser identificado e removido pelo suspeito; (2) ter alta probabilidade de transferência e retenção, a fim de permanecer aderido em superfícies e objetos por longos períodos de tempo; (3) permitir-se ser individualizado, a ponto de ser possível sua discriminação entre amostras de mesma classe; (4) ser facilmente coletado, separado e concentrado, seguindo protocolos padrões para comparação entre casos distintos; (5) ser facilmente caracterizados, com reproduzibilidade e repetibilidade; (6) ser consultável em bancos de dados computadorizados, de forma a promover a intercomunicação dos casos investigados; e (7) ser imutável diante de fatores ambientais ou temporais, uma vez que intervalos podem ocorrer entre a data do crime, a coleta do material e o processamento da amostra. Com exceção deste último item, dada a dinâmica da pedogênese ao longo do tempo geológico e as variações sazonais em sua composição biogeoquímica, além da possibilidade de degradação ou alteração dos componentes após armazenamento, o solo atende a todos os demais parâmetros de forma satisfatória e tem potencial para se tornar um dos vestígios mais relevantes para a perícia (Fitzpatrick *et al.*, 2009).

Em termos de visibilidade, o primeiro critério mencionado por Aardahl (2003), sabe-se que mesmo quantidades de solo invisíveis a olho nu podem ser identificadas e processadas, tanto em escala micro (Fitzpatrick & Raven, 2019) quanto nanoscópica (Liu *et al.*, 2015), seja por técnicas ópticas (Palenik, 2007), eletrônicas (Cengiz *et al.*, 2004;

Kikkawa *et al.*, 2019; Pirrie, 2018; Pye & Croft, 2007) ou de tunelamento quântico (Konopinski *et al.*, 2012).

Já capacidade de transferência e retenção do solo é influenciada por diversos fatores, como o tipo de tecido das vestes (Procter *et al.*, 2019); a umidade, teor de argila, composição do solo, tamanho e modelo do sapato utilizado (Werner *et al.*, 2019). Além disso, (Morgan *et al.*, 2019) demonstraram que diferentes pontos do solado (como região do calcanhar ou ponta do dedos) também retém proporções diferentes de solo, de acordo com a distância percorrida pelo agente.

Em relação à variabilidade e individualização de amostras, heterogeneidades podem ser observadas nas propriedades biogeoquímicas do solo em diferentes escalas, desde intervalos micrométricos, como a presença de micronichos de bactérias em subdomínios de 1 a 100 μm^3 (Pedersen *et al.*, 2015; Ranjard *et al.*, 2000; Yang *et al.*, 2020), até centimétricos a métricos, exemplificado pelas diferenças colorimétricas em solos espaçados com cerca de 10 metros entre si (Cheshire *et al.*, 2017; Corrêa *et al.*, 2018; McCulloch & Dawson, *et al.*, 2017; McCulloch *et al.*, 2018; McCulloch & Morgan, *et al.*, 2017), e até mesmo entre centenas e milhares de quilômetros (Guo *et al.*, 2019; Salvador *et al.*, 2019), com base em assinaturas isotópicas ou assembleias palinológicas distintas.

2.1.2 Técnicas de coleta e análise

Diversas instituições de pesquisa internacionais já elaboraram guias e procedimentos operacionais padrão (POP) para a amostragem e processamento de amostras de solo para fins forenses, como o James Hutton Institute (Dawson, 2019), Centre for Australian Forensic Soil Science (Fitzpatrick & Raven, 2016), European Network of Forensic Science Institutes (ENFSI, 2019), American Society for Testing and Materials (ASTM E3272 - 21) e o Forensic Geoscience Group da Geological Society of London (Donnelly, 2020).

Cada norma técnica aborda as especificidades do local onde será aplicado, tendo como base a demanda, recursos humanos e financeiros e aspectos geográficos. No Brasil, o procedimento adotado para a coleta segue aquele estabelecido por Testoni *et al.* (2019), em que define como perímetro de amostragem um quadrante de lado 1,5 m,

podendo ter em sua coordenada central o vestígio questionado, como marcas de solado, pegadas ou rodagem de pneus, objetos ou cadáveres, cujo substrato também é coletado, somando-se 5 amostras por ponto, em um profundidade designada de 0 à 5 cm, corroborando com a estratégia de amostragem baseada em quadrantes estratificados de Pye (2007).

Uma vez que a capacidade de transferência e retenção do solo é função dos teores de silte e argila, busca-se separar este intervalo granulométrico de interesse antes de iniciar os procedimentos analíticos. No entanto, há diferentes formas de interpretação a respeito dos limites destas classes. Enquanto Krumbein (1934), Wentworth (1922) e a *International Organization for Standardization* (ISO) pela norma ISO 14688-1:2002 (British Standards Institution, 2002) estabelecem como limite areia-silte o diâmetro 62,5 µm (usualmente arredondado para 63 µm), a ASTM D2487-00 (2000) define o valor de 75 µm e o *United States Department of Agriculture* (USDA, 1996) adota a faixa de 50 µm.

Em termos de aplicação forense, não há um consenso sobre a faixa granulométrica ideal para separação (Tabela 1). Na literatura, é possível encontrar estudos de caso utilizando limites superiores desde 50 até 400 µm. A profundidade de amostragem, todavia, não costuma ultrapassar os primeiros 5 cm, correspondente à camada com maior interação antrópica, usualmente.

Além disso, é comum, durante uma investigação forense, que apenas uma amostra muito pequena seja recuperada para análise e confronto. Conforme os equipamentos analíticos modernizam, cada vez menos material é necessário para se obter um perfil químico ou biológico da amostra, de forma que já é possível encontrar estudos de caso envolvendo o processamento de 0,05 g (Jarvis *et al.*, 2004), 0,5 g (Melo *et al.* (2019), 1,7 g (Testoni *et al.*, 2019), 1,98 g (Concheri *et al.*, 2011) e < ~1,0 g (Stern *et al.*, 2019) de amostra de solo. Entretanto, cautela é sempre recomendada nesses casos para evitar o consumo integral dos vestígios, visto a imprescindibilidade da contraperícia (Decreto-Lei nº 3.689/1941, Art. 158-B, inciso IX). Em face disso, outra vertente da Criminalística avança no sentido do aprimoramento de técnicas não-destrutivas ou micro-destrutivas, para medição de atributos físicos, químicos ou biológicos.

Tabela 1 - Levantamento bibliográfico dos intervalos granulométricos e profundidades de amostragem em estudos de caso envolvendo a análise forense de vestígios de solo.

<i>Referência</i>	<i>Faixa granulométrica (μm)</i>	<i>Profundidade de amostragem (cm)</i>
Testoni <i>et al.</i> (2019)	< 53	0 – 5
Melo <i>et al.</i> (2019)	< 53	0 – 3
Guo <i>et al.</i> (2019)	< 74	*
Fitzpatrick & Raven (2019)	< 50	*
Fitzpatrick (2013)	< 50	*
Fitzpatrick & Raven (2012)	< 400	0 – 2
Lee <i>et al.</i> (2012)	< 63	*
Guedes <i>et al.</i> (2011)	< 63	0 – 5
Fitzpatrick <i>et al.</i> (2009)	< 50	0 – 3
Jarvis <i>et al.</i> (2004)	< 150	0 – 5
Dudley & Smalldon (1978)	< 125	*

* Não especificado no trabalho.

Atributos físicos

A principal propriedade geofísica medida em amostras de solo em estudos forenses é a susceptibilidade magnética (Guedes *et al.*, 2013; Manrong *et al.*, 2009; Pringle *et al.*, 2015), reflexo da magnetização espontânea (Kearey *et al.*, 2009) de minerais magnéticos tanto neoformados na pedogênese, como a maghemita, quanto herdados do protólito, a exemplo da magnetita, ilmenita e pirrotita.

A gamaespectrometria, por sua vez, tem sua aplicação voltada para a Ciência Forense Nuclear, com o propósito de avaliar a concentração de radionuclídeos como ^{210}Pb , ^{234}Th , ^{226}Ra , ^{235}U e ^{137}Cs em matéria prima contrabandeada para manufatura de artefatos bélicos nucleares (Eppich, 2020; Kristo *et al.*, 2016; Lützenkirchen *et al.*, 2019; Reading *et al.*, 2015). Não há registro na literatura da aplicação desta técnica em vestígios de solo coletados em cenas de crime, para fins de confronto ou proveniência geográfica. No entanto, é um método amplamente e comumente utilizado na caracterização de materiais geológicos, principalmente para fins de exploração mineral de hidrocarbonetos ou de estudos ambientais.

Atributos químicos

Em termos físico-químicos, o método não-destrutivo mais amplamente utilizado para análise forense de materiais geológicos (Chauhan *et al.*, 2018, 2020; Cox *et al.*, 2000; Hassan *et al.*, 2019; Robertson *et al.*, 2015; Sangwan *et al.*, 2020; Xu *et al.*, 2020) é a espectroscopia de infravermelho com transformada de Fourier (FTIR), a qual permite a obtenção de informações sobre a presença de grupos funcionais presentes na estrutura química da amostra, com base em valores de absorbância ou transmitância nas respectivas bandas associadas a um intervalo de comprimento ou número de onda. Os principais grupos funcionais observados em um espectro de solo orgânico são (Ma *et al.*, 2021): estiramento O-H em argilominerais hidratados (3.610 cm^{-1}), N-H (3600-3000 cm^{-1}), estiramento C=C em amidas e aromáticos (1660-1600 cm^{-1}), estiramento de H₂O ligada à argilas (1630 cm^{-1}), estiramento CO₃⁻² em carbonatos (1434 cm^{-1}), estiramento C-H em radicais metila (1445-1350 cm^{-1}), estiramento Si-O em minerais silicáticos (995 cm^{-1}), deformações angulares de Al-O em caulinitas e esmectitas (915 cm^{-1}), estiramento C-O de carbonatos (872 cm^{-1}) e deformações fora do plano da NH₂ em aminas (posicionadas a 771 cm^{-1}).

A espectroscopia de fluorescência de raios-X portátil (pXRF) é uma técnica analítica bastante promissora para a casuística forense pois permite obter, de forma rápida e não-destrutiva, o teor de uma série de elementos químicos presentes na amostra, podendo atingir penetrações na ordem de micrômetros até poucos milímetros, a depender do tipo e estrutura da matriz (Thompson, 2009). Diversos trabalhos já demonstraram a utilização desta técnica em casos envolvendo microvestígios (Bergslien, 2013; Hou *et al.*, 2004; Shimamoto *et al.*, 2013).

Apesar da facilidade e conveniência no uso, Bergslien (2019) levantou alguns pontos significativos a serem considerados, com base nas limitações inerentes ao próprio equipamento: (a) a superfície exposta da amostra deve ser larga, homogênea e espessa o suficiente para interagir de forma uniforme com todos os feixes incidentes, que dependem das especificações do equipamento e energia aplicada; (b) a amostra deve estar completamente seca pois água atenua drasticamente o sinal refletido; (c) a superfície da amostra deve ser regular e plana para garantir a geometria correta do feixe; (d) o tipo e espessura do plástico que compõe a embalagem de acondicionamento da

amostra influencia de forma substancial nos resultados, atenuando a concentração de elementos de baixo número atômico – a título de exemplo, sacos de polietileno (PE) de 0,004" podem atenuar até 100% do teor de alumínio e cerca de 97% para silício e 93% para fósforo; (e) alguns elementos apresentam picos de energia muito próximos, induzindo o *software* de interpretação automática do aparelho a confundir sua identificação – para ilustrar, os picos $K\beta$ do potássio, $L\alpha$ do antimônio, $K\alpha$ do cálcio e $L\alpha$ do telúrio apresentam valores entre 3,58 e 3,80 keV, havendo possibilidade de erro caso o operador não avalie cada espectro separadamente. Outras precauções indicadas pela autora estão relacionadas com (f) a atenuação de sinal devido a presença de matéria orgânica; (g) espalhamento elástico (ou de Rayleigh), inelástico (ou de Compton) e picos de difração (ou de Bragg), em que concentrações obtidas variam de acordo com o ângulo de rotação da amostra.

Atributos colorimétricos

Por fim, uma das principais propriedades de um solo investigado é a cor. Apenas com este atributo, foi possível discriminar cerca de 97% das amostras (Dawson & Hillier, 2010), quando combinados os componentes de cor na amostra sob condição seca, úmida, inorgânica e após remoção de óxidos de ferro, entre solos de origem vulcânica, aluvial e residual. O sistema de cores mais utilizado na ciência do solo é a carta de Munsell (1975), o qual decompõe a cor nos parâmetros de matiz, saturação e luminosidade. No entanto, por conta de suas limitações, principalmente por depender da percepção e acurácia visual do operador (Marqués-Mateu *et al.*, 2018), outros espaços de cor estão sendo frequentemente utilizados na literatura (Viscarra Rossel *et al.*, 2006), como os sistemas RGB (vermelho, verde e azul), CIE L*a*b (luminosidade, coordenada vermelho/verde e amarelo/azul), HSL (matiz, saturação e brilho) e HSV (matiz, saturação e valor), os quais permitem a medição direta na amostra por meio de colorímetros digitais. Atualmente, a colorimetria é uma técnica indispensável em qualquer estudo de solo para fins criminalísticos (Aitkenhead *et al.*, 2013; Antoci & Petraco, 1993; Croft & Pye, 2004; Dong *et al.*, 2020; Dudley, 1975; Guedes *et al.*, 2009; Pye *et al.*, 2006; Sugita & Marumo, 1996; Zeng *et al.*, 2020).

2.2 Predição da proveniência de vestígios geológicos

Murray (2004), em sua obra “*Evidence from Earth: Forensic Geology and Criminal Investigation*”, considerada a primeira bibliografia geoforeNSE do mundo, cita dezenas de casos históricos de aplicações empíricas de estudos de proveniência de materiais geológicos em casos criminais, em que investigadores puderam definir limites geográficos para orientar buscas por locais de ocultação de cadáveres, cemitérios clandestinos, esconderijos de bens roubados e outros objetos ou veículos de interesse foreNSE. Com a ausência de bancos de dados, utilizavam-se mapas geológicos, mapas de solos, bases topográficas e de cobertura vegetal para comparação indireta, ou até mesmo era levada em consideração a experiência do próprio geocientista em levantamentos de campo anteriores.

Os primeiros esforços em prol do desenvolvimento de um método matemático e estatisticamente embasado para este propósito surgem no início deste século por Rawlins & Cave (2004). O primeiro estudo envolveu a utilização de dados de um levantamento geoquímico regional de solo superficial (0 – 15 cm) no leste da Inglaterra, realizado pelo Serviço Geológico Britânico (BGS) em uma área de 13.000 km², onde teores de 23 elementos maiores e traços obtidos por XRFs em 50 g de 6.500 amostras foram avaliados quanto a variabilidade espacial, grau de incerteza analítica, capacidade de discriminação da unidade litoestratigráfica de origem e distância Mahalanobis para os pares de amostras de cada unidade. A partir disso, foi possível discriminar mais de 99,8% das amostras e obter assinaturas geoquímicas para cada classe litológica. Contudo, os autores já alertavam sobre a necessidade de se equiparar os métodos de amostragem e análise do levantamento geoquímico regional com aqueles utilizados na rotina foreNSE, uma vez que, como já exemplificado aqui (Jarvis et al., 2004; Melo et al., 2019; Testoni et al., 2019; Concheri et al., 2011; Stern et al., 2019), é comum a recuperação de pequenas quantidades de amostra questionada.

Rawlins et al. (2006) realizaram um experimento em que forneceram a 4 especialistas dados obtidos por DRX, MEV, assembleia palinológica e cromatografia gasosa acoplada à espectrometria de massas (GC/MS) de matéria orgânica do solo provenientes de 3 locais distintos do Reino Unido e, a partir de bases cartográficas, os mesmos deveriam indicar possíveis regiões de origem destes materiais. Quando os

resultados analíticos foram observados de forma independente, as interpretações foram, em parte, errôneas, e os profissionais foram induzidos ao erro devido a atributos pouco distintivos. No entanto, quando múltiplas propriedades foram combinadas, a exatidão das conclusões diagnósticas mostraram-se superiores, indicando, assim, a importância de se trabalhar sempre com diferentes abordagens no conjunto analítico.

Diversos são os trabalhos que buscaram aproveitar as bases cartográficas governamentais existentes para aplicar no contexto forense (Tabela 2). Lark & Rawlins (2008) aplicaram funções de verossimilhança espacial e PCA nos mesmos dados de XRFS utilizados por Rawlins & Cave (2004) e puderam validar um modelo de predição de proveniência a partir de amostras do próprio banco, de forma que a magnitude da área de busca foi inversamente proporcional a quantidade de componentes principais utilizados nas funções.

Stern *et al.* (2019), ao investigarem um caso de sequestro seguido de homicídio e ocultação de cadáveres nos EUA ocorrido em 2004, compararam vestígios de solo aderidos a pás do suspeito com diversos mapas digitais, incluindo: mapa geológico, mapa de teores de argilominerais de 10-Å no horizonte A, cobertura vegetal e distribuição palinológica, integrando as bases por meio de algoritmos Bayesianos em ambiente SIG e atribuindo valores entre 0 e 1 para verossimilhança relativa entre as amostras questionadas e as classes mapeadas no banco. A partir disso, os autores puderam delimitar áreas de busca preferenciais tanto em escala continental, quanto no entorno das covas, excluindo-se mais de 97% do território total e com acurácia superior a 90%.

Hoogewerff *et al.* (2019) utilizaram modelos de distribuição espacial da razão isotópica (também denominado *isoscape*, a partir da junção dos termos *isotope* e *landscape*) de $^{87}\text{Sr}/^{86}\text{Sr}$ biodisponíveis no solo superficial de toda a Europa, construídos durante o projeto GEMAS (*Geochemical Mapping of Agricultural and Grazing land Soil*) da EuroGeoSurveys (*European Geoscience for Society*) a fim de validar um método de predição baseado unicamente nesta técnica, além de ser aplicável para qualquer tipo de material inorgânico ou biológico, incluindo alimentos, tecidos humanos, artefatos arqueológicos ou vestígios de solo. A partir da avaliação da razão de verossimilhança entre 1200 amostras controle e questionadas geradas aleatoriamente, foi possível estimar extensas regiões para exclusão ou busca prioritária.

Tabela 2 - Levantamento bibliográfico dos trabalhos relacionados à predição de proveniência de vestígios de solo, com informações sobre o método de predição, técnicas analíticas, população amostral, área total, clima local e profundidade de amostragem. Em negrito, o estudo objeto desta dissertação, para fins de comparação.

Referência	Localização	Clima †	Área (km ²)	n	Método de predição	Prof. (cm)	Métodos analíticos
Este trabalho	Região Metrop. de Curitiba, Brasil	Cfa	100	232	Intervalos de confiança, distância euclidiana e ML‡	5	SM, gamaespec., colorimetria, pXRF e FTIR
De Caritat et al. (2021)	North Canberra, Austrália	Cwb	260	268	Intervalos de confiança	5	MS, FTIR, FRX, ICP-MS
Ma et al. (2021)	Hunter Valley, Austrália	Cwb	328	488	PCA e redes neurais	10	pXRF
De Caritat et al. (2019)	New South Wales, Australia	Cwb	800.642	*	Intervalos de confiança	5	P e N totais, pH (CaCl ₂), granulometria
Stern et al. (2019)	EUA	**	9.834.000	*	Verossimilhança relativa	Horiz A	DRX, assembleia palinológica
Hoogewerff et al. (2019)	Europa	**	10.180.000	1200	Razão de verossimilhança Bayesiana	10	Razão isotópica de ⁸⁷ Sr/ ⁸⁶ Sr
Menchaca et al. (2018)	Califórnia, EUA	Csa	93	255	Análise discriminante tipo stepwise	5	SM, granulometria, colorimetria
Tighe et al. (2018)	New South Wales, Australia	Cwb	7,5	160	PLS, PCR e EARTH	5	vis-NIR, pXRF
Aitkenhead et al. (2014)	Escócia	Cfb	77.910	721	Redes neurais	10	Colorimetria, granulometria, pH, CTC, LOI, ICP-AES.
Lark & Rawlins (2008)	Humber-Trent, Inglaterra	Cfb	10.000	5411	Razão de verossimilhança e PCA	15	XRFS
Saye & Pye (2004)	Inglaterra e País de Gales	Cfb	200	>1500	Índice de similaridade	5	Granulometria e ICP-AES

† Segundo a classificação climática; ‡ ML = *Machine learning*; * Dados matriciais; ** Estudo aplicado em todo o território do país, com múltiplas variações climática; Prof. = Profundidade.

De Caritat *et al.* (2019) foram precursores no desenvolvimento de uma ferramenta de predição com base em estimativas de intervalos de confiança. Utilizando-se matrizes de interpolação de dados de fósforo e nitrogênio totais, pH (CaCl_2) e granulometria do solo superficial (0 – 5 cm) construídas pela CSIRO (*Commonwealth Scientific and Industrial Research Organisation*) na região de New South Wales (Austrália), os autores aplicaram equações para delimitar estatisticamente intervalos de confiança considerando os valores da amostra para cada variável e uma margem de tolerância superior e inferior, atribuindo valores booleanos para cada pixel que satisfizer ou não a equação. O produto final, por sua vez, foi a soma algébrica dos *rasters* reclassificados, onde as células com maiores valores representaram as zonas de origem da amostra questionada. O método, mesmo sendo destinado apenas a amostras maiores que 1,0 g, teve como vantagens poder ser aplicado em escalas continentais; ter alta resolução espacial; e ter transparência, reproduzibilidade e objetividade. Para as 3 amostras de validação, o modelo conseguiu indicar com exatidão as áreas de provável origem, podendo reduzir o perímetro de busca para até 8,4% da área original.

Apesar dos resultados relativamente satisfatórios dos estudos utilizando bases cartográficas previamente desenvolvidas por órgãos governamentais, é comum existir conflito metodológico entre as rotinas laboratoriais aplicadas no levantamento regional e na casuística forense, principalmente em termos de protocolo analítico e de amostragem. Essas discrepâncias, além de poderem inviabilizar o uso do banco de dados para aplicação na Criminalística, podem induzir o operador ao erro fornecendo um resultado enviesado, caso não haja conhecimento prévio dessas limitações (Rawlins *et al.*, 2006).

Com base nisso, alguns autores têm dado especial atenção à iniciativa de construção de um banco destinado exclusivamente para o estudo de métodos de predição de proveniência para vestígios geológicos. Sendo assim, Menchaca *et al.* (2018) amostraram 255 amostras de solo (0 – 5 cm) em uma área de 93 km² ao sul da Califórnia (EUA), com precauções acerca da densidade amostral em cada unidade litoestratigráfica e pedológica presentes no perímetro de estudo. Cerca de 18 variáveis foram obtidas por meio de colorimetria, determinação da susceptibilidade magnética e granulometria. A partir de análise discriminante do tipo *stepwise* em um estudo cego para validação do modelo, foi possível estimar com acurácia a unidade geológica de origem

de 22% das amostras-teste na primeira opção de saída do algoritmo, 22% na segunda e 16% na terceira, chegando a excluir até 95% da área de proveniência.

Em seu trabalho mais recente, De Caritat *et al.* (2021) coletaram amostras de solo superficial (0 – 5 cm) em 268 pontos na região de *North Canberra* (Austrália), em uma área de cerca de 260 km², submetendo as amostras para análise de ICP-MS, FRX, FTIR e susceptibilidade magnética. A partir da análise de componentes principais (PCA) e utilizando-se o mesmo método de predição com intervalos de confiança descrito em De Caritat *et al.* (2019), obteve-se uma precisão máxima de 80,7% quando combinados os dados de susceptibilidade magnética, FTIR e PCA.

Até então, não há na literatura um método de predição de proveniência forense universal perfeitamente acurado e que atenda e abranja as heterogeneidades dos vestígios de solos encontrados em cenas de crime. Os estudos já publicados admitem generalizações para as condições físicas e químicas sob as quais as amostras questionadas são recuperadas – entretanto, sabe-se que a dinâmica e interações entre o vestígio e os componentes relacionados ao crime são imprevisíveis e seguem um sistema aberto, causando diferenciação na composição, estrutura e tamanho da amostra.

Além disso, cada trabalho considera as particularidades do ambiente e aspectos físicos nos quais será inserido, o que contribui diretamente para diferentes valores de variabilidade e preditibilidade das propriedades do solo. A título de exemplo, dados de susceptibilidade magnética podem não ser tão relevantes estatisticamente em áreas geologicamente homogêneas (ex: extensos derrames vulcânicos) quando comparado com regiões que afloram unidades de diferentes classes e domínios (ex: greenstone belts).

2.3 Aprendizagem de máquina supervisionado

Aprendizagem de máquina, do inglês *machine learning*, refere-se a um campo de estudo da Ciência da Computação voltado à exploração de algoritmos de análise e predição de dados de forma automatizada, a partir do reconhecimento de padrões e da aplicação de ferramentas estatísticas avançadas. Com base em um conjunto de observações específicas de entrada, o código é induzido a estabelecer uma regra geral

e fornecer resultados de saída que atendam a determinadas condições: em um exemplo simples, se no passado o sol nasceu todo dia pela manhã, supõe-se que amanhã ele seguirá o mesmo padrão e aparecerá no mesmo período. Quando o *output* é limitado a uma série finita de valores discretos (tempo ensolarado/nublado/chuvoso), o problema de aprendizagem envolve classificação de dados – por outro lado, quando se trabalha com valores numéricos, tem-se a aplicação da regressão (horário exato do nascer do sol) (Russell & Norvig, 2021).

Há pelo menos três formas de abordagem no processamento dos dados por *machine learning*: (a) aprendizagem supervisionada, quando envolve observações prévias de pares de entrada-saída para geração de um modelo que satisfaça estas relações para aplicação posterior; (b) aprendizagem não-supervisionada, quando o algoritmo, sem treinamento prévio, observa e identifica padrões estruturais nos dados de entrada, agrupando-os com base em seus atributos (*clustering*); e (c) aprendizagem por reforço, onde o algoritmo é treinado a partir de premiações ou punições após determinadas ações serem tomadas, semelhante ao adestramento de cães. Há também o método de aprendizagem semi-supervisionada, em que os dados de treinamento estão incompletos e possuem saídas ausentes (Russell & Norvig, 2021).

Em relação à aprendizagem supervisionada, dado um conjunto de pares de dados de treinamento gerados pela função desconhecida, o objetivo do algoritmo será construir e avaliar a hipótese ou modelo que satisfaça a verdadeira relação entre os pares. Este modelo, por sua vez, pode adotar as mais variadas funções matemáticas, seja ela linear, polinomial ou exponencial, sem limitação (Russell & Norvig, 2021).

Existem dezenas de algoritmos de aprendizagem supervisionada, cada um com sua aplicação específica. Os mais utilizados na literatura são: (a) redes neurais artificiais (RNA), (b) árvores de decisão, (c) floresta aleatória, (d) regressão linear, (e) regressão logística, (f) máquinas de vetores de suporte (SVM), (g) k-vizinhos mais próximos (kNN) e (h) *gradient boosting*.

As redes neurais artificiais (RNA ou ANN) são modelos de predição inspirados no sistema nervoso central, em que os neurônios correspondem a nós interconectados dispostos em camadas de entrada, de saída e intermediárias/ocultas. Cada nó é composto por um conjunto de funções e cada conexão possui um peso específico, que

é atribuído aos valores de entrada e em cada transferência entre camadas (Schmidhuber, 2015). As RNAs podem ser classificadas em redes paraconsistentes ou *perceptron* - este último no formato simples ou multicamadas (MLP) (Ruppert, 2004). O método MLP, aplicado nesta pesquisa, consiste em um conjunto de camadas com retropropagação de erro (*backpropagation*), em que há processamento reverso para correção de erros através do reajuste de pesos (Rumelhart *et al.*, 1986). Cada nó do algoritmo perceptron, então, busca separar linearmente os dados de entrada em dois grupos distintos. Após a etapa de aprendizagem e validação, o modelo pode ser aplicado na predição de dados desconhecidos.

Aitkenhead *et al.* (2014) foram os primeiros a aplicar algoritmos de redes neurais artificiais (RNA) em modelos de predição de proveniência de vestígios de solo. A partir de dados de levantamentos geoquímicos regionais do Inventário Nacional de Solos da Escócia (NSIS), com informações sobre colorimetria, granulometria, pH, CTC, LOI e ICP-AES da camada superficial do solo (0 – 10 cm). Foi possível, deste modo, reduzir a área de busca para até 1,23 km² (ou 0,002% do território da Escócia).

De forma semelhante, Ma *et al.* (2021) realizaram o mesmo procedimento em uma área de 328 km² na região de *Lower Hunter Valley*, na Austrália, onde foram amostras 488 amostras controle de solo superficial (0 – 10 cm) e analisadas por espectrometria de raios-X portátil (pXRF). Com auxílio da análise de componentes principais (PCA), o perímetro de busca pôde ser reduzido entre 5 e 28% da área total.

3. MATERIAIS E MÉTODOS

3.1 Amostragem

A base de dados utilizada é composta por 286 amostras coletadas nos 100 km² da área de estudo (Tabela 3). As amostragens foram divididas em três categorias: (a) 232 amostras controle (Figura 5), coletadas a uma profundidade máxima de 5 cm e seguindo o Procedimento Operacional Padrão para coleta de amostras para fins forenses no Brasil (Testoni *et al.*, 2019); (b) 40 amostras do horizonte pedológico B; e (c) 14 amostras questionadas, produzidas em simulações controladas de transferência primária de vestígios, utilizando-se superfícies de ferramentas, vestes e pneus (Figura 6). Exceto para estas últimas, nos demais pontos foram coletados cerca de 1,0 kg de amostra. Ao todo, foram necessários 8 dias de campo para cobrir toda a área de estudo.



Figura 5 - Ferramentas utilizadas para a coleta das amostras-controle na área de estudo, em uma profundidade de até 5 cm.

Os pontos de amostragem foram selecionados tendo como critério a baixa interferência urbana, como regiões de floresta e terrenos desocupados, e demarcados a

partir de observações em imagens de satélite pretéritas. Em cada ponto, a cobertura vegetal foi removida para facilitar a coleta. Ferramentas e embalagens estéreis foram utilizadas e higienizadas entre cada amostragem para evitar contaminação cruzada.

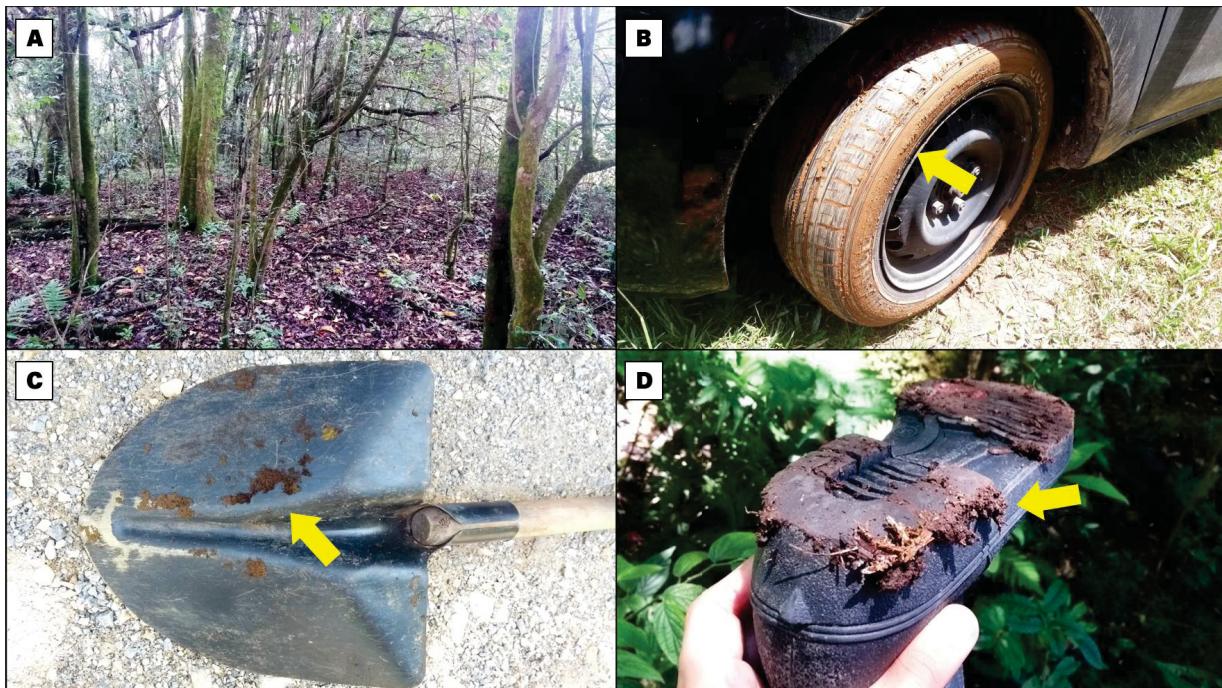


Figura 6 - Exemplos de locais onde foram realizadas as coletas de amostras controle (a) e de amostras de validação (questionadsa) em pneus (b), ferramentas (c) e sapatos (d).

Em termos de densidade amostral do grupo de controle, houve uma variação de 1,1 a 6,8 amostras/km², para as unidades QPg e JKd, respectivamente. Em média, obteve-se uma densidade de 2,3 amostras/km² em toda a área de estudo.

Tabela 3 - Densidade amostral segundo as unidades litoestratigráficas presentes na área de estudo

Unidade	Descrição simplificada ^a	Área (km ²)	Amostras controle	Amostras horiz. B	Amostras de validação	Densidade amostral ^b (amostra/km ²)
Qha	Sedimentos aluvionares recentes.	4,7	10	2	1	2,1
QPg	Argilas, areias e cascalhos inconsolidados.	3,8	4	1	0	1,1
QPg2	Argilas, siltes, areias e cascalhos depositados em depressões kársticas.	14,4	45	6	1	3,1
JKd	Diques de diabásio.	5,5	37	10	0	6,8
PSacm	Metasedimentos siltic-argilosos.	35,7	67	12	5	1,9
PSacd	Mármore dolomíticos e metadolomitos.	2,2	5	0	0	2,3
PSacq	Quartzitos, metarenitos e metarcóseos.	0,5	2	0	0	4,1
Plagn	Migmatitos com biotita-hornblenda gnaisse.	33,3	62	9	7	1,9
Total		100,0	232	40	14	2,3

^a Segundo o Mapeamento Geológico-Geotécnico do Instituto Água e Terra (IAT, 2021);

^b Densidade amostral referente às amostras controle do horizonte superficial (< 5 cm).

As áreas dos Polígonos de Thiessen/Voronoi (Figura 7) indicam uma distribuição gaussiana levemente assimétrica positiva (equivalente a 0,91), podendo-se concluir que algumas regiões foram amostradas de forma preferencial, espacialmente enviesadas, indicado pelos polígonos de cor clara e seus respectivos pontos agrupados. Do mesmo modo, as áreas de influência também sugerem que regiões específicas apresentaram menor resolução amostral (em km²/amostra), representados pelos polígonos de cor azul escuro.

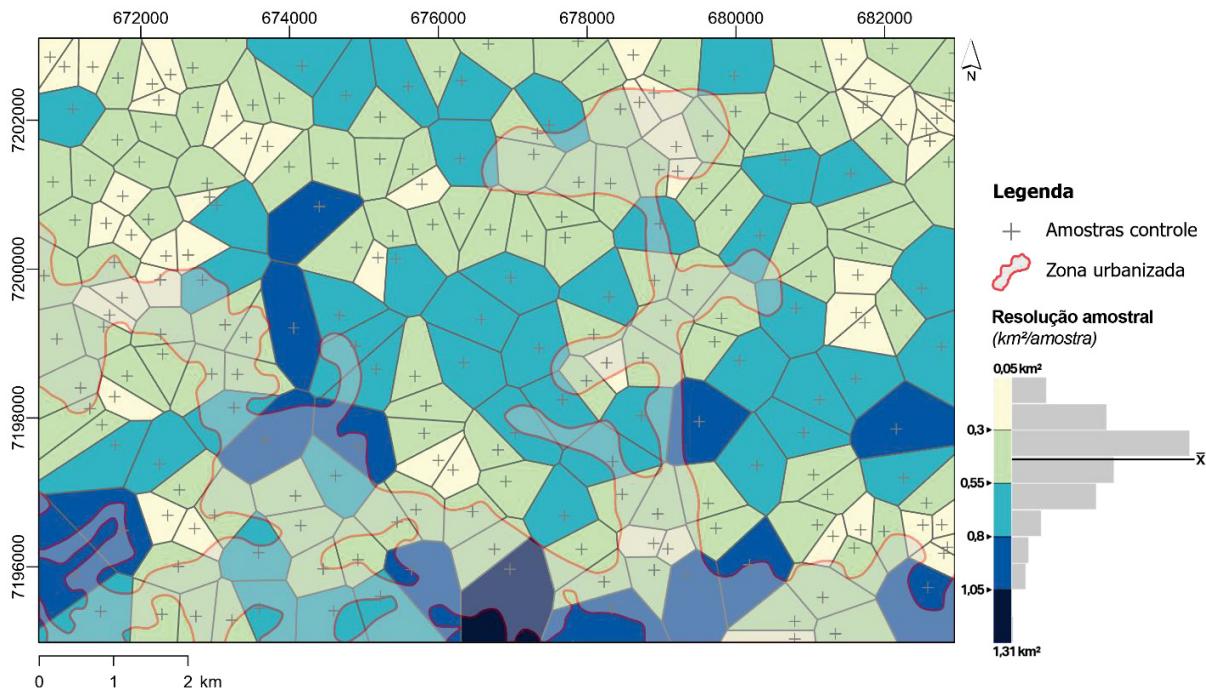


Figura 7 - Mapa dos triângulos de Voronoi classificados segundo as respectivas resoluções amostrais (áreas de abrangência de cada amostra), com indicação dos pontos de coleta das amostras controle. O histograma exibe a distribuição das áreas dos polígonos.

Os principais motivos que levaram à irregularidade na malha de amostragem foram a dificuldade de acesso a certas áreas, topografia acidentada e a presença de centros urbanos (conforme ilustrados na Figura 7). Entretanto, pela assimetria não ser muito pronunciada, optou-se por não aplicar o método de desagrupamento poligonal proposto por Pyrcz & Deutsch (2007), cuja correção envolve a atribuição de pesos às variáveis de forma diretamente proporcional ao tamanho da área de influência de cada ponto.

3.2 Análises não-destrutivas

No âmbito forense, é de suma importância que haja preservação e acondicionamento de contraprova durante todo o processo judicial. Vestígios de solo coletados em cenas de crime usualmente estão presentes em baixíssimas quantidades, na escala de micro a miligramas (Fitzpatrick & Raven, 2019; Guo *et al.*, 2019; Melo *et al.*, 2019). Quando mantidos sob protocolos de cadeia de custódia (Lei nº 13.964/2019),

recomenda-se que as amostras não sejam integralmente consumidas durante os exames, uma vez que há a possibilidade de novas perícias serem requisitadas durante o andamento do processo na Justiça.

3.2.1 Fluxograma analítico e preparação das amostras

Por conseguinte, neste trabalho, 5 métodos de análise não-destrutiva foram selecionados para caracterizar as amostras de solo (Figura 8): análise de susceptibilidade magnética, gamaespectroscopia portátil, colorimetria, espectroscopia de fluorescência de raios-X portátil (pXRF) e espectroscopia no infravermelho com transformada de Fourier e reflectância total atenuada (ATR-FTIR).

Após a coleta, todas as amostras foram submetidas aos mesmos procedimentos de preparação e análise. Inicialmente, as amostras foram levadas à estufa para secagem à 30°C, sendo posteriormente homogeneizadas e desfragmentadas. Uma alíquota padrão de 50 cm³ foi reamostrada e utilizada ao longo de todas as etapas analíticas.

3.2.2 Análises radiométricas e de susceptibilidade magnética

O primeiro passo envolveu a análise de susceptibilidade magnética, em medidor Terraplus KT-10 no modo *scanner*, e de gamaespectroscopia portátil, utilizando-se um RS-230 BGO Super-SPEC de 1024 canais, configurado no modo *assay* e com tempo de integração de leituras de 120 s, em isolamento por placa de chumbo, para medições das concentrações dos radionuclídeos ²³⁸U, ²³²Th e ⁴⁰K, no intervalo de 30 à 3.000 keV.

3.2.3 Separação granulométrica e colorimetria

Após as análises geofísicas, as alíquotas seguiram para dispersão química em Na₄P₂O₇ com agitador rotativo e peneiramento por via úmida, a fim de separar três faixas granulométricas: (I) fração maior ou igual a grânulo (> 2 mm), (II) fração arenosa (63 µm à 2 mm) e (III) fração siltíco-argilosa (< 63 µm). Após a separação, as três subamostras foram secas em estufa a 70°C.

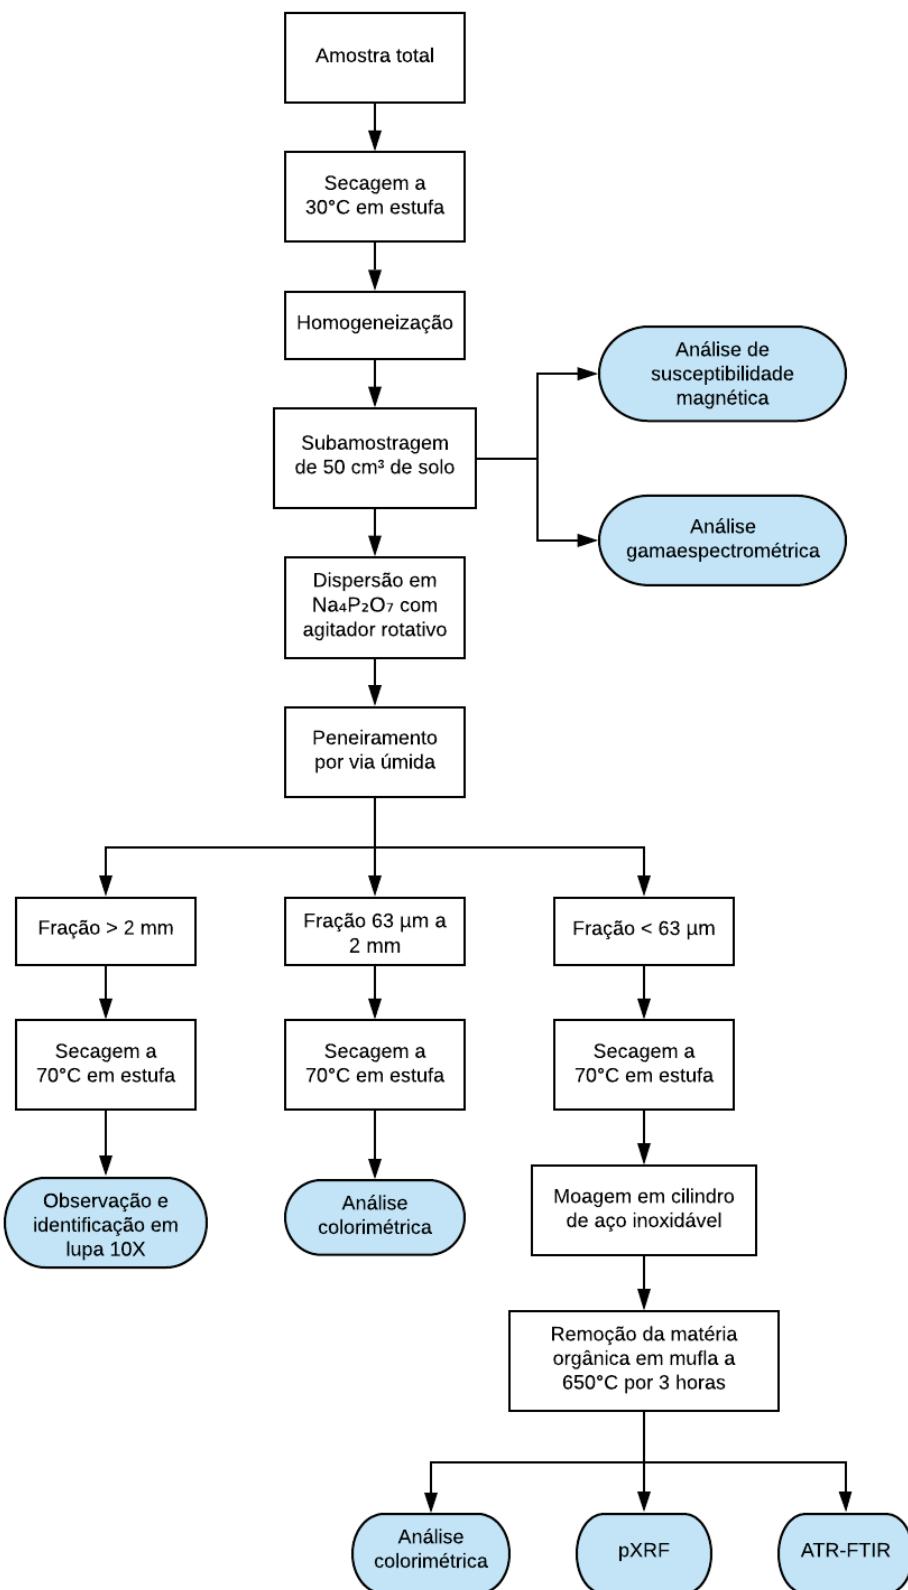


Figura 8 - Fluxograma analítico aplicado nas amostras coletadas em campo. Em azul, as técnicas analíticas adotadas; em branco, os procedimentos para tratamento das subamostras.

A fração I foi utilizada majoritariamente para identificar fragmentos líticos e minerais a partir da observação em lupa de 10 aumentos. A fração II, por sua vez, foi encaminhada para colorimetria utilizando um analisador ACR-1023, para determinação dos índices de cor dos sistemas HSL (matiz, saturação e brilho, de 0 a 1.000) e RGB (vermelho, verde e azul, de 0 a 1.023), na escala de 400 à 700 nm, com precisão de 5%.

3.2.4 Espectroscopia de fluorescência de raios-X portátil (pXRF)

A fração III, de maior interesse forense, foi submetida à moagem em cilindro de aço inoxidável e à remoção da matéria orgânica por ignição em mufla a 650°C por 3 horas. Além da colorimetria, o produto pulverizado e inorgânico resultante foi examinado quimicamente por pXRF, modelo Olympus Innov-X DS-2000 Delta, com tubo de ródio de 40 kV e 200 µA e detector por deriva de silício (SDD), para determinação dos teores de Fe, Ti, Zr, Mn, Nb, V, Ni, Pb, Zn, Cu, Bi e do grupo dos elementos leves (LE), composto por Si, Mg e Al. As leituras foram realizadas diretamente sobre as amostras, em intervalos de 30 s, de acordo com as considerações levantadas por Bergslien (2019).

3.2.5 Espectroscopia no infravermelho com transformada de Fourier (ATR-FTIR)

Na sequência, a mesma fração foi analisada em um FTIR modelo Thermo Nicolet 380 com ATR Smart Orbit de cristal de diamante, no intervalo de 4000 a 400 cm⁻¹ e com 32 scans. Valores de absorbância de seis bandas espectrais principais foram extraídas para integrar o banco de dados: 1060 cm⁻¹ (estiramento assimétrico Si-O-Si), 1435 cm⁻¹ (estiramento da carbonila C=O), 780 cm⁻¹ (torção vibracional Si-O-Fe), 688 cm⁻¹ (deformação angular Si-O), 520 cm⁻¹ (torção vibracional Si-O-Al) e 450 cm⁻¹ (deformação angular assimétrica Si-O-Si).

3.3 Tratamentos estatísticos e geoestatísticos

Ao todo, foram obtidas 28 variáveis numéricas contínuas e regionalizadas, com distribuição não-gaussiana e em diferentes unidades de medida. A primeira etapa de processamento envolveu a normalização dos dados através da transformação log-normal, tanto para readequá-los em uma mesma ordem de grandeza, quanto para transformar as distribuições assimétricas enviesadas em normais simétricas, aproximando a média da mediana.

Em seguida, os dados foram inseridos em ambiente SIG (*ArcGIS Pro 2.8*) para realização de estimativas geoestatísticas em toda a área utilizando a krigagem bayesiana empírica (EBK) com regressão preditiva, estabelecidas por Gribov & Krivoruchko (2020). A partir da inserção de matrizes explicativas, ou seja, correlatas à variável a ser interpolada, as mesmas são convertidas para seus Componentes Principais (PC) e, na sequência, são aplicadas equações de Mínimos Quadrados Ordinários (OLS) para cálculo dos resíduos da regressão - estes, por sua vez, são modelados a partir de semivariogramas, construídos através de uma abordagem de máxima verossimilhança restrita (REML). O diferencial deste método, no entanto, é que permite tratar a variância local separadamente, por meio da segmentação da área em diferentes blocos sobrepostos entre si para execução da krigagem (Krivoruchko & Gribov, 2019).

As incertezas na modelagem espacial foram avaliadas a partir de parâmetros obtidos em validações cruzadas entre os pontos observados e seus correspondentes gerados na interpolação. O principal atributo é a raiz do erro quadrático médio normalizado ou relativo (RRMSE), o qual é definido pela razão entre a raiz do erro quadrático médio (RMSE), ou também chamada de desvio padrão dos resíduos da validação cruzada, e a média dos valores medidos em laboratório. O produto desta divisão, portanto, indica a acurácia do modelo em prever as propriedades do solo em regiões que não foram amostradas, sendo melhor conforme se aproxima de zero. Outra métrica para avaliar o desempenho do algoritmo de modelagem é a raiz do erro quadrático médio padronizado (RMSSE), o qual indica a variabilidade do erro ao comparar o erro de predição com o erro de predição padrão – caso seja superior a 1, a variabilidade do erro de predição está subestimada e, se inferior a 1, superestimada.

Adicionalmente, foram observadas as médias das pontuações contínuas de probabilidade classificada (CRPS), o qual mede os desvios na função de distribuição acumulada das previsões para cada ponto. Logo, espera-se, para fins de controle de qualidade, que a CRPS seja o menor possível. Já a média do desvio padrão do erro (ASE), ou média do erro padrão, indica a variação do erro distribuído ao longo da área de estudo, devendo ser próximo de zero – aqui, a ASE foi normalizada por log-normal. Avaliou-se, também, as porcentagens dos valores gerados na validação cruzada contidos no intervalo de confiança do percentil 95%, as quais devem aproximar-se deste número.

Para interpolação das variáveis geofísicas (susceptibilidade magnética e teores de ^{238}U , ^{232}Th e ^{40}K) foram utilizados, como matrizes explicativas, dados do levantamento aerogeofísico do Projeto Paraná - Santa Catarina (CPRM, 2011), com linhas de voo espaçadas em 500 m na direção N-S e altura de voo em 100 m, com intervalos entre medições de 0,1 s (magnetômetro) e 1,0 s (espectrômetro). No caso dos dados aeromagnetométricos, foram aplicados, no campo magnético anômalo (CMA), filtros de redução ao polo (RTP) e continuação descendente de 30 m (*downward continuation*) para realce de fontes rasas, com interpolação bidirecional. Já para os dados aerogamaespectrométricos, fez-se uso do método da mínima curvatura (Briggs, 1974). Utilizou-se o software Geosoft Oasis montaj.

No caso das demais variáveis, os modelos geoestatísticos tiveram como base o Mapa Geológico-Geotécnico da Região Metropolitana de Curitiba (RMC) em escala 1:20.000 elaborado pelo Instituto Água e Terra (IAT, 2021), com apoio da Coordenação da Região Metropolitana de Curitiba (Comec).

3.4 Modelos de predição de proveniência

Três métodos de predição de proveniência foram escolhidos para aplicar neste trabalho: (a) definição dos intervalos de busca (ou confiança) utilizados por de Caritat et al. (2019, 2021); (b) cálculo da distância euclidiana entre as amostras cegas com o banco de dados de amostras controle; e (c) aprendizagem de máquina supervisionada.

3.4.1 Método dos intervalos de confiança

No primeiro método, atribui-se o valor 1 para cada pixel que estiver contido dentro do intervalo $x \pm IC$, onde x refere-se ao valor da amostra cega e IC ao intervalo de confiança, definido pelo desvio padrão da matriz do banco de dados; e 0 para o pixel que estiver fora deste intervalo. Sendo assim, o modelo final de predição é composto pela soma algébrica das 28 matrizes binárias, de forma que as áreas de alta probabilidade de proveniência são indicadas pelos pixels de valores mais elevados. O *raster* final é reclassificado em quatro subgrupos por meio de intervalos geométricos, os quais são definidos por limites baseados em séries de progressões geométricas, indicado para visualização de dados com distribuição assimétrica.

3.4.2 Método das distâncias euclidianas

Já o segundo método é definido pela distância euclidiana n -dimensional (d) entre as amostras cegas (x) e as amostras controle (c), podendo ser representada da seguinte forma:

$$d(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_i)^2}$$

Os resultados finais das distâncias d , por sua vez, são interpolados utilizando-se a técnica do Inverso do Quadrado da Distância (IQD). Esta matriz é então reclassificada em três subgrupos a partir de intervalos por quebras naturais. Logo, as áreas de menor distância d indicam as áreas onde há maior chance de acerto na proveniência.

3.4.3 Métodos de aprendizagem supervisionada

De forma complementar, foram testados (no *software* Orange 3.3) 7 algoritmos de aprendizagem de máquina supervisionada para inferir a proveniência por unidade litoestratigráfica ou classe pedológica, onde os modelos foram construídos utilizando as

próprias amostras controle como dados de treinamento rotulados para produzir as funções, e as amostras cegas foram inseridas como alvos. Foram avaliados:

- (1) redes neurais artificiais (RNAs) do tipo perceptron multicamadas (MLP) com retro-propagação, onde foram compiladas 100 camadas ocultas com otimização do tipo Adam;
- (2) máquinas de vetores de suporte (SVM), com função *kernel RFB (radial basis function)* e parâmetro custo (C) de 1,0;
- (3) árvore de decisão, com indução de árvore binária e, no mínimo, duas instâncias por folha;
- (4) regressão logística, em regularização do tipo Lasso (L) e força (C) equivalente a 3,0.
- (5) k-vizinhos mais próximos, com 5 vizinhos, métricas euclidianas e pesos uniformes;
- (6) *gradient boosting*, pelo método *scikit-learn*, onde foram construídas 100 árvores a uma taxa de aprendizagem de 0,1 e profundidade máxima de árvores individuais igual a 3.
- (7) floresta aleatória, com 10 árvores, sem dividir subgrupos menores que 5.

4 RESULTADOS E DISCUSSÕES

Os resultados, discussões e conclusões desta dissertação serão apresentados na sequência no formato de artigo científico, a ser submetido em periódico internacional.

Evaluating geostatistical methods along with non-destructive analysis for forensic provenancing organic-rich soils in humid subtropical climate

Matheus P. N. e Silva^{a,b,*}, Carlos C. F. Guedes^b

^a Paraná State Scientific Police, Environmental Crimes Unit, 150 Paulo Turkiewicz St., Curitiba, 82821-030, Brazil

^b Department of Geology, Federal University of Paraná, 100 Cel. Francisco H. dos Santos Ave., Curitiba, 81530-000, Brazil

Abstract

When no samples are available for direct comparisons during a criminal investigation, forensic scientists must resort to georeferenced soil databases in order to find the source of a single questioned evidence. To this end, several authors addressed many methods to infer the origin of soil samples, such as establishing search range intervals or defining statistical similarities. However, little is currently known about the efficiency of these methods when it comes to highly weathered subtropical soils. Therefore, this study attempts to contribute to this subject by evaluating the predictability of a soil database built in a 100 km² area in the Curitiba Metropolitan Region, Brazil, where 232 topsoil (< 5 cm), 14 validation, and 38 subsoil samples (B horizon) were collected. To determine their physical, chemical, and colorimetric features, samples were subjected to magnetic susceptibility analysis, gamma-ray spectrometry, color analysis, pXRF, and ATR-FTIR. Two prediction methods were used: search range intervals (SR) and n-dimensional Euclidean distances (ED). After the descriptive and multivariate statistical analyses, geostatistical models were generated for the 28 obtained variables using the empirical Bayesian kriging (EBK) with regression prediction method, where geological and airborne geophysical data were used as explanatory matrix. For the ED provenancing method, dissimilarity values were calculated and interpolated by applying the inverse distance weighting (IDW) approach. Findings, while preliminary, suggest that magnetic susceptibility, lightness, Fe, Mn, Cu, Ni, and the light elements group (LE) may be the most significant variables to discriminate parent rock and to correlate with subsurface data. The SR method managed to correctly predict the origin of 4 of 14 validation samples, reducing up to 97.5% of the original area. The ED method, on the other hand, accurately estimated the provenance of 8 out of 14 samples, excluding up to 63.4% of the area. Despite the limitations and errors inherent to non-destructive analyses, the intense chemical weathering, and the high organic matter content, overall soil provenancing results were suitable, demonstrating that spatial variability of topsoils developed under humid subtropical environments can be modeled and used in forensic contexts, as long as the right methods are applied.

Keywords: Forensic soil analysis. Provenance prediction. Geostatistical modeling. Supervised learning.

1. INTRODUCTION

Much has been written on the use of soil as physical evidence in forensic investigations (Dawson & Hillier, 2010; Dudley & Smalldon, 1978; Fitzpatrick & Raven, 2005; Guedes *et al.*, 2011; Pirrie *et al.*, 2013; Prandel *et al.*, 2020). Many authors have fully addressed different methods of sampling (Donnelly, 2020; Fitzpatrick & Raven, 2016; Pye, 2007; Testoni *et al.*, 2019), analysis (Cengiz *et al.*, 2004; Chauhan *et al.*, 2020; Guedes *et al.*, 2009; Kammrath *et al.*, 2018; Konopinski *et al.*, 2012; McCulloch, Morgan, *et al.*, 2017; Morgan & Bull, 2007; Pye & Croft, 2007; Ruffell & Wiltshire, 2004; Xu *et al.*, 2020), and interpretation (Ispahding, 2004; Morgan *et al.*, 2009; Morgan & Bull, 2006; Reidy *et al.*, 2013) of geological materials found in crime scenes, suspects, vehicles, or alibi sites. Forensic geoscientists worldwide provided critical information in cases related to murder (Brown *et al.*, 2002; L. J. Donnelly *et al.*, 2019; R. Fitzpatrick *et al.*, 2017; Petracco *et al.*, 2008; Smale & Trueman, 1969; Testoni *et al.*, 2020), theft (Salvador *et al.*, 2019; Testoni *et al.*, 2019), body exhumation (McPhee, 1996), rape (Horrocks & Walsh, 1999; Kasu & Shires, 2015; Stella *et al.*, 2020), wildlife crime (Coimbra & Coutinho, 1976; de Bruin & Schmitz, 2021), and many other situations, based entirely on forensic soil or sediment analysis. In most circumstances, investigators follow a direct comparison approach, where they must define degrees of similarity or likelihood ratios between one or more pairs of questioned and control samples. However, in some situations, a unique soil sample may be the only resource available and the expert must provide intelligence regarding its geographical source.

Despite the many empirical applications of forensic soil provenancing in the twentieth century (Murray, 2004a), one of the first attempts (Rawlins & Cave, 2004) to evaluate spatial variability, measurement uncertainty, and bedrock discrimination using data from regional soil surveys has shown that these databases can be useful in establishing the origin of unknown soil evidence, even when dealing with small amount of sample. However, the authors already warned about the risks of performing those links based on signatures datasets built under contrasting protocols of collection and analysis. In the following years, several studies managed to ‘recycle’ soil surveys published by government agencies, by testing geostatistical prediction algorithms such as likelihood functions (Hoogewerff *et al.*, 2019; Lark & Rawlins, 2008; Stern *et al.*, 2019), neural

networks (Aitkenhead *et al.*, 2014), and multivariate regressions (Tighe *et al.*, 2018), in different types of data (XRD, XRF, vis-NIR, ICP-AES, grain size, $^{87}\text{Sr}/^{86}\text{Sr}$ isotope ratio, pH, and pollen assemblage), and sampling depths ranging from 5 to 15 cm.

Even though these initiatives achieved satisfactory results and had perfect predictions, they may face major usage restrictions due to methodology mismatches when inserted into crime labs routines. Most soil traces found in crime scenes adhered to surfaces rarely exceed more than 2,0 g (Concheri *et al.*, 2011; Jarvis *et al.*, 2004; Melo *et al.*, 2019; Testoni *et al.*, 2019), limiting the analytical approach upon which the sample will be submitted to. In most modern justice systems, both the defense and prosecution have the right to inspect and retest forensic evidence stored under chain of custody protocols – that means that laboratory analysts must preserve and safeguard a sample aliquot large enough to allow the double-checking later in Court, at risk of contributing to overturning a conviction in case of misconduct (NCFS, 2014). Therefore, depending on the size of the questioned sample, non-destructive techniques should be prioritized over destructive ones (Keaney *et al.*, 2009). For example, quantitative XRF, although it allows sample recovery, it requires at least 1,0 g of material for preparing the fusion beads and measuring the loss on ignition (LOI) weight.

Several authors aimed to develop and evaluate topsoil databases set up exclusively for forensic purposes (de Caritat *et al.*, 2021; Ma *et al.*, 2021; Menchaca *et al.*, 2018; Saye & Pye, 2004). These previous approaches managed to (a) predict the bedrock of blind samples at a 22% success rate under stepwise discriminant analysis for Mediterranean soils in southern California, U.S. (Menchaca *et al.*, 2018); (b) geolocate sand grains found in a glove associated with a burial site in a nearby beach, after comparison to forensic coastal dune sediment database, in Lincolnshire coast, U.K. (Saye & Pye, 2004); (c) narrow the search area to 5% of the original extent after similarity, principal component and artificial neural network analysis in Lower Hunter Valley, Australia, using a pXRF-built soil database (Ma *et al.*, 2021); and (d) achieve an 80.7% precision rate in provenancing blind samples along with compositional data acquired on a forensic soil survey in North Canberra, Australia (de Caritat *et al.*, 2021), while applying the Search Range (SR) method (de Caritat *et al.*, 2019).

Notwithstanding the recent progress in sourcing pedological evidence, no efforts have been made to understand the challenges when dealing with organic-rich soils developed under humid subtropical climates, typically found in the southeastern regions of South America, Mainland China, Africa, Australia, and the U.S. In this research, we intend to contribute to this subject by setting up a forensic topsoil database in Southern Brazil based on non-destructive analysis and testing the Search Range (SR) and Euclidean distance provenancing methods.

The region of interest (Figure 1) consists of a 100 km² area in Curitiba Metropolitan Region, Paraná State, southern Brazil, and comprises both urbanized and countryside communities. Due to a recent growth in Brazilian organized crime, mainly associated with drug trafficking, the place became a murder and body disposal hotspot, especially in areas with Atlantic Forest. Therefore, while this study explores concepts of soil provenancing, it could provide local authorities an operational tool to support ongoing and upcoming investigations.

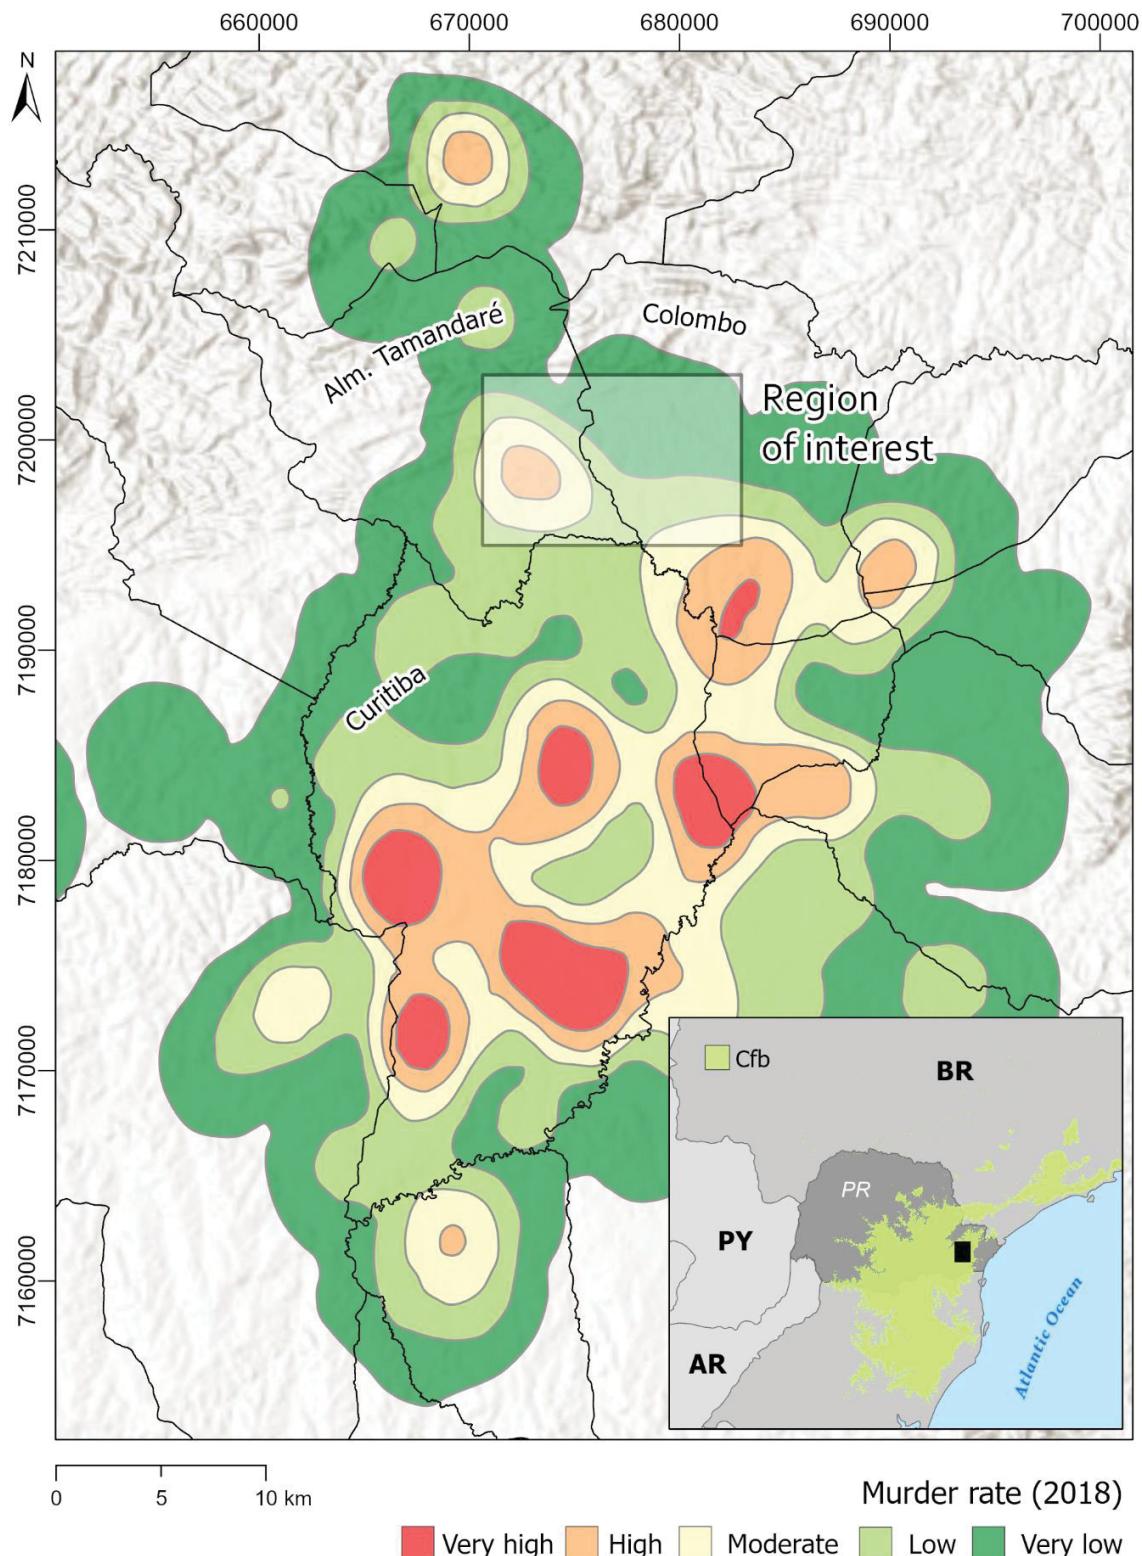


Figure 1 - Heatmap displaying the murder rate of the Curitiba Metropolitan Region in 2018. Gray rectangle indicates the region of interest (ROI) and the black lines represents the cities boundaries. Bottom right map shows the climatic classification according to Köppen-Geiger.

1.1 Geological and pedological background

The designated area (Figure 2a) is located within the southern segment of the Ribeira Folded Belt (RFB), a Meso-Neoproterozoic NNE-SSW mobile belt related to the Pan-African/Brasiliano orogenic cycle (Campos Neto, 2000; de Brito Neves *et al.*, 1999) that comprises the Curitiba Terrane (Fiori, 1992; Santos *et al.*, 2021), which shelters the Açuñui Supergroup and its low-grade metadolomites (PSacd), phyllites (PSacm), and quartzites (PSacq), and the basement rocks of the Atuba Complex (Plagn), that comprehends one-third of the study area and consists of Paleoproterozoic banded biotite-hornblende gneisses, amphibolites, and several granitoids (Siga Junior *et al.*, 1995).

Sectioning the entire perimeter in the NW-SE direction, the diabase dyke swarm (JKd) from the Lower Cretaceous Paraná-Etendeka Magmatic Province (PEMP) (Thiede & Vasconcelos, 2010) represents as little as 5,5% in surface area but can be seen cross-cutting enclosing rocks both in regional and outcrop scale. Found mainly in the southern portion, the Curitiba Basin (Vieira & Fernandes, 2020) integrates a set of Cenozoic sedimentary basins related to NE-SW grabens from the Southern Brazil Continental Rifts (RCSB) system (Salamuni *et al.*, 2003) and is filled solely by the Guabirotuba Formation, a Paleogene lithostratigraphic unit (QPg and QPg2) that hosts intercalated gravels, clays, and calcretes, deposited in alluvial fans and karst landforms under semi-arid climate (Lima *et al.*, 2013; Oliveira *et al.*, 2011). Meandering rivers flowing in the area are responsible for producing many Quaternary channels, overbank, and points bar deposits (Qha).

In terms of pedological taxonomy (Figure 2b), seven different classes of soil occur in the region (Embrapa, 2013), including clayey aluminous Humic Cambisols (CHA); Haplic Cambisols (CXbd), with lower aluminum toxicity and organic matter (SOM), usually correlated to gently undulating landforms; dystrophic Red Latosols (LBd), which can be found either in its typical, cambic and clayey conditions; dystrophic Red-Yellow Argisols (PVAd), ranging from medium to high SOM rate; iron-rich dystrophic Red Nitrosols (NVdf), commonly associated to basic or ultrabasic rocks; Mesic Organosols (OY) with higher SOM, mostly found in low-relief floodplains; and Melanic Gleysols (GM), with higher cation exchange capacity (CEC) and SOM, and dark and thick A horizon.

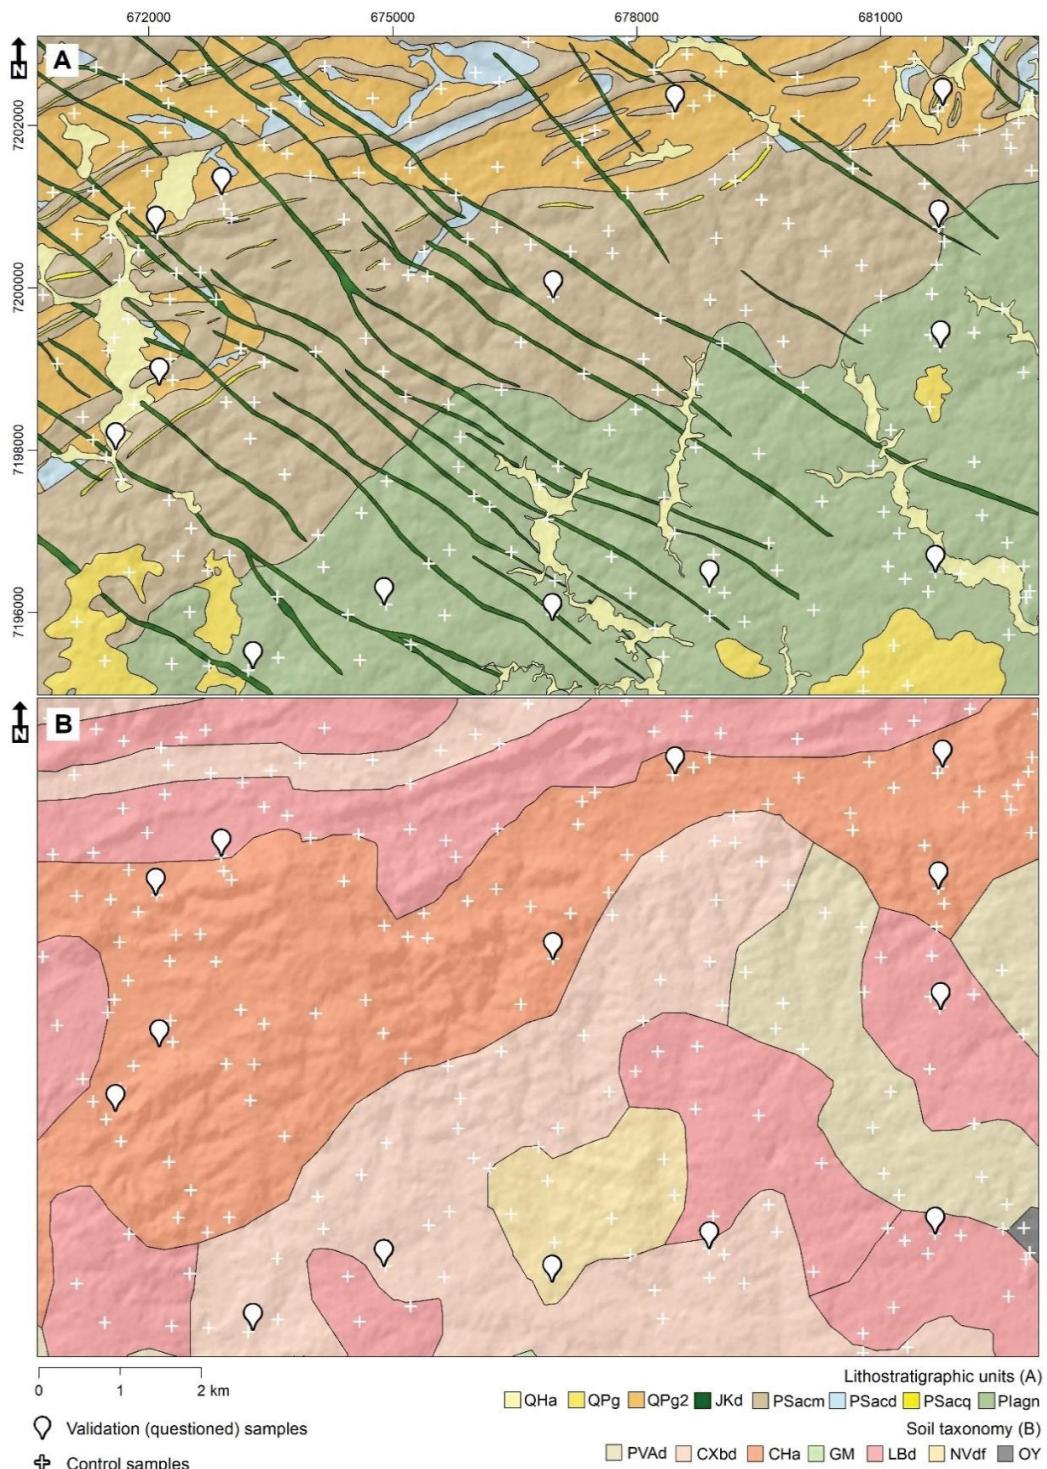


Figure 2 - Geological (A) and pedological map (B) of the study area. Qha: recent sediments; QPg and QPg2: sediments from the Curitiba basin; JKd: basaltic dykes from the Paraná-Etendeka Magmatic Province (PEMP); PSacm, PSacd, and PScq: phyllites, dolomites, and quartzites from the Açuungui Supergroup; Plagn: migmatitic gneisses of the Atuba Complex. PVad: red-yellow Argisols; CXbd: haptic Cambisols; CHa: humic Cambisols; GM: melanic Gleysols; LBd: red Latosols; NVdf: red Nitrosols; and OY: mesic Organosols. White pins and crosses represent the validation and control samples, respectively.

1.2 Climate and geomorphological features

Curitiba Metropolitan Region (RMC) has a humid subtropical climate (Cfb, also known as warm temperate with no dry season) (Alvares *et al.*, 2013), reaching an average annual precipitation rate of up to 1575 mm and an average temperature of 17.4 °C. Two major morphosculptural units design the local landscape, the Curitiba and Tunas do Paraná Plateaus. The first one presents medium dissection, a predominant convex slope of 6%, and landforms composed of elongated and flattened hilltops and “V” valleys, modeled and controlled by the Atuba Complex rocks. The latter corresponds to a high dissected terrain, presenting a flat to gently undulating straight slope (< 6%), “V” valleys, and elongated and ridged hilltops, where the general morphological direction varies between NW-SE, when dyke-controlled, and NE-SW when restrained by the Açuñui Supergroup. Due to intense weathering, soil profiles may reach a depth of up to 40 m, as seen in groundwater wells data drilled throughout the place.

2. MATERIALS AND METHODS

2.1 Soil sampling

Taken altogether, 286 were collected in the region of interest, which can be divided into three categories: (a) reference, (b) validation, and (c) subsurface samples. The topsoil dataset was assembled after sampling 232 reference samples from the 0 – 5 cm interval, using sterile plastic spades and polyethylene plastic bags for storing ~1,0 kg of material, making sure to properly clean the tools between collections to avoid cross-contamination. In addition, 40 samples from the B horizon were also obtained in road cuttings to evaluate vertical variability. In order to test the prediction algorithms, 14 soil samples were retrieved from simulated evidence, such as vehicle tires, spades, and footwear. Sampling sites were selected preferably in woodland fields, keeping away from landfills, urban centers, and crops.

Regarding sampling density, there was a range from 1.1 to 6.8 samples/km², corresponding to the QPg and JKd units, respectively. On average, 2.3 samples were collected across every square kilometer inside the study area. Thiessen (or Voronoi)

polygons indicate a slightly right-skewed distribution, suggesting a small spatial sampling bias, primarily due to inaccessibility and urbanization. However, we opted to not apply declustering and debiasing (Pyrcz & Deutsch, 2007).

2.2 Sample preparation

After collection, every sample was submitted to the same pre-analytical treatments. Initially, samples were oven-dried at 30 °C for 24 hours and later disaggregated and homogenized. A standard aliquot of 50 cm³ was resampled and submitted to chemical dispersion using 0.2M tetrasodium pyrophosphate in a motor-driven stirrer for 30 minutes. The solution proceeded to wet-sieving in stainless steel sieves, aiming to get separated into three particle-size classes: coarser fraction I (> 2 mm), sandy fraction II (2 – 0.063 mm), and the fine fraction III (< 0.063 mm), following Udden-Wentworth grain-size scale (Wentworth, 1922). Afterwards, each sub-sample was dried at 70 °C. The silt-clay group, in particular, was grounded using a stainless steel pin and submitted to organic matter removal by pyrolysis at 650 °C for 3 hours in a muffle furnace (Cox *et al.*, 2000). Every sample was stored in an 80 µm thick polyethylene (PE) resealable bag.

2.3 Non-destructive analysis

Prior to granulometric segregation, bulk analysis was performed in the specimens aiming to obtain their radiometric and magnetic properties. An RS-230 BGO Super-SPEC handheld gamma-ray spectrometer was used to quantify ²³⁸U, ²³²Th e ⁴⁰K radionuclei concentrations, with 1024 channels and energy range between 30 to 3000 keV, set in assay mode for 120 seconds readings. In addition, magnetic susceptibility (MS) data in 10⁻⁶ SI units were obtained after using a handheld Terraplus KT-10 on scanner mode.

The gravel-size components in fraction I were identified and described using a 10x magnifying glass. Both subsamples II and III were sent to quantitative colour analysis in an Instratherm® ACR-1023 handheld analyzer to acquire the HSL (hue, saturation, and lightness), from 0 to 1.000, and RGB (red, green, blue), ranging from 0 to 1023, color coordinates, in the 400 to 700 nm spectral interval, at ± 5% precision.

The fine soil fraction III, which commonly detain a stronger capacity for transfer and retention on objects (Fitzpatrick *et al.*, 2009), received a deeper examination regarding its chemical and physical attributes. Heavy elements were estimated by semi-quantitative pXRF analysis using an Olympus Innov-X DS-2000 DELTA Professional with a 4W Rh X-ray tube operating at 40 kV/200 μ A and silicon drift detector (SDD) in single beam mode, detecting Fe, Ti, Zr, Mn, Nb, V, Ni, Pb, Zn, Cu and Bi, grouping Si, Al, and Mg in the light elements (LE) label. Surveys were carried out in 30 seconds scans in close proximity to the samples, without plastic bag cover, except for the 6 μ m prolene film window.

Functional groups were also investigated by Fourier transform infrared spectroscopy (FTIR) alongside the attenuated total reflection (ATR) sampling mode, in a Thermo Nicolet™ 380 with a Smart Orbit diamond crystal, covering the mid-infrared region (4000 to 400 cm^{-1}) in 32 successive scans. Six spectral bands were identified and quantified: (a) 1060 cm^{-1} (Si-O-Si asymmetric stretching), 1435 cm^{-1} (C=O asymmetric stretching), 780 cm^{-1} (Si-O-Fe vibrational twisting), 688 cm^{-1} (Si-O bending vibration), 520 cm^{-1} (Si-O-Al vibrational twisting), and 450 cm^{-1} (O-Si-O bending vibration).

2.4 Geostatistical models

Twenty-eight numeric variables were assembled during the analytical procedures in order to support the forensic soil database. Due to non-Gaussian distributions and distinct magnitudes of measurement, a log-normal transformation was applied for data normalization. Statistical hypothesis testing was performed following two methods: (a) Shapiro-Wilks normality test (Shapiro & Wilk, 1965), to evaluate data distribution; and (b) Wilk's Lambda multivariate analysis of variance (one-way MANOVA) test, in order to check any difference between the means of the geological and pedological units for each soil property. Principal component analysis (PCA) on the variance-covariance matrix was applied as well.

For every single variable, a geostatistical model was generated by applying empirical Bayesian kriging (EBK) regression prediction (Gribov & Krivoruchko, 2020), a method that estimates an ordinary least squares (OLS) regression model based on explanatory variables and calculates a series of semivariograms for the error term, using

a restricted maximum likelihood (REML) approach and dividing the dataset into overlapping subsets, dealing with local variance independently (Krivoruchko & Gribov, 2019). Uncertainty was evaluated according to the relative root-mean-square error (RRMSE), which is defined by the ratio between the root-mean-square error (RMSE, equivalent to the standard deviation of the residuals) and the average value of measured data - indicating the model accuracy in forecasting values at unsampled locations, which should be closer to zero. The root-mean-square standardized error (RMSSE), also calculated, measures the assessment of the prediction variability by performing cross-validation between the prediction error and the prediction standard error. If RMSSE is greater than one, the variability of the prediction is underestimated - if less than one, it is overestimated.

Additionally, the average Continuous Ranked Probability Score (CRPS) was evaluated as well, which indicates how much the predictive cumulative distribution function deviates at each measured point and should be as little as possible. The average standard error (ASE), also calculated, represents the mean value of the prediction standard errors, and the 95th percentile shows the percentage of points distributed within the 95% cross-validation confidence interval.

For the interpolation of the geophysical parameters, data from the airborne geophysical survey run by the Geological Survey of Brazil in 2011 were used as an explanatory matrix. The systematic collection was conducted with a flight altitude and line spacing of 100 and 500 m, respectively, in the N-S direction. For the magnetic data, which were sampled every 0.1 s, reduction to the pole (RTP) filter and downward continuation of 30 m were applied in the anomalous magnetic field, aiming to highlight shallow sources. Moreover, gamma-ray spectrometry data (uranium, thorium, and potassium channels) were gathered with a 1.0 s gap between measurements, which was gridded after the minimum curvature method (Briggs, 1974).

2.5 Provenancing tools

Two provenancing methods were selected to evaluate the soil database predictive potential: the search ranges algorithm (de Caritat *et al.*, 2019, 2021) and the Euclidean distance between pairs of questioned and reference samples. The first one is based on

boolean value assignments to pixels that satisfy (or not) a search range condition, which is defined as a confidence interval around a target value (corresponding to a questioned sample). For example, considering a target sample with 15% Fe and its upper and lower limits set to $\pm 3\%$, a cell with 17.3% Fe would be assigned the value of 1. Therefore, the end prediction model is composed of the sum of a maximum of 28 logical matrices. Furthermore, the final raster was reclassified into four geometric classes, where the highest one indicates the most probable area of origin.

The second method comprises the n -dimensional Euclidean distance between the blind sample and each cell grid, where n is defined as the number of variables involved in the computation. The product is then interpolated by inverse distance weighting (IDW) and reclassified into three natural breaks subsets.

3. RESULTS

3.1 Descriptive statistics

A statistical summary is presented in Table 1. The lowest relative standard deviation (RSD) calculated on normalized data is found in the light elements (LE) group (1.1%), followed by ^{238}Th (3.8%), saturation index (4.7%), Bi (5.0%), redness (5.3%), and Nb (6.0%) variables. In contrast, Ti (859,7%), MS (46,0%), Fe (30,3%), and Mn (27,0%) presented the most spread-out values. The average RSD for all properties is 13.6%.

Shapiro-Wilk test shows that the majority of variables reject the null hypothesis ($p < 0.05$) and therefore are not normally distributed, except for ^{235}U , ^{238}Th , R (redness), C=O, 688, and Si-O-Si. For this reason, the whole dataset was log-transformed to stabilize variance and optimize regression modeling, as previously stated. Regarding Wilks' Lambda one-way MANOVA test, MS ($p < 0.001$) and Cu ($p < 0.001$) stands out as the most discriminant variables to distinguish lithostratigraphic units, along with ^{238}U , LE, Fe, Ti, Zr, Mn, hue, lightness, and the RGB indices, considering $p < 0.05$. Compared to soil units, a statistically significant difference was found between soil classes only when evaluating Cu values ($p < 0.001$), followed by MS ($p = 0.09$). PCA analysis indicates that the first principal component (PC1) is strongly correlated to MS and moderately correlated to Fe, Ti, and Mn data, explaining 39.2% of the total variance, while PC2 is mostly

influenced by ATR-FTIR data, accounting for 18.0% of maximum variability, as the first ten PC sums up 93.3% of the total variance. A notable relation was found between Wilk's Lambda and PC1 values.

Table 1 - Summary statistics of the datasets, including the quantitative analysis of distribution, variance, error, and range. Results of Shapiro-Wilk and Wilks' Lambda statistical tests are described below, as well as the first two principal components.

	MS (S.I.)	40K (%)	235U (ppm)	238Th (ppm)	LE (%)	Fe (%)	Ti (%)	Zr (%)	Mn (%)	Nb (%)
Descriptive statistics										
Average	0,167	2,081	2,232	10,183	92,049	6,675	1,103	0,037	0,068	0,003
Median	0,049	2,100	2,200	10,200	93,215	5,560	0,935	0,033	0,045	0,002
Variance	0,088	0,011	0,122	0,787	18,899	14,586	0,412	0,001	0,005	0,000
Std. Dev.	0,297	0,104	0,350	0,887	4,347	3,819	0,642	0,027	0,070	0,002
Std. Error	0,298	0,104	0,351	0,889	4,357	3,827	0,644	0,027	0,070	0,002
Minimum	0,004	1,600	1,300	7,900	75,300	0,997	0,090	0,008	0,007	0,001
Maximum	2,010	2,300	3,100	12,900	98,860	21,830	4,100	0,381	0,438	0,020
Range	2,006	0,700	1,800	5,000	23,560	20,833	4,010	0,373	0,431	0,019
Skewness	3,002	-0,373	0,111	0,117	-1,407	1,486	1,434	8,776	2,546	8,176
Kurtosis	10,191	1,272	-0,323	-0,287	2,009	2,191	3,366	108,381	7,650	90,319
Shapiro-Wilk Normality Test										
W value	0,550	0,908	0,987	0,995	0,883	0,868	0,900	0,483	0,706	0,470
p-value	< 0.001	< 0.001	0,032	0,598	< 0.001	< 0.001	< 0.001	< 0.001	< 0.001	0,000
Wilks' Lambda MANOVA test										
Geological units										
F value	8,449	0,616	3,798	1,341	3,232	2,941	2,798	2,846	2,646	1,217
p-value	< 0.001	0,654	0,011	0,273	0,023	0,033	0,040	0,037	0,049	0,320
Soil taxonomy										
F value	2,579	0,197	1,978	0,148	0,920	1,548	0,412	2,371	1,088	0,451
p-value	0,089	0,822	0,152	0,863	0,407	0,225	0,665	0,107	0,347	0,640
Principal component analysis										
PC1	-0,116	-0,141	-0,085	0,099	0,568	-0,525	-0,562	-0,480	-0,076	-0,344
PC2	0,485	0,123	-0,375	0,186	-0,696	0,701	0,447	0,029	0,161	-0,093

Table 1 Continued - Summary statistics of the datasets, including the quantitative analysis of distribution, variance, error, and range. Results of Shapiro-Wilk and Wilks' Lambda statistical tests are described below, as well as the first two principal components.

	V (%)	Ni (%)	Pb (%)	Bi (%)	Zn (%)	Cu (%)	H	S	L
Descriptive statistics									
Average	0,045	0,005	0,006	0,004	0,007	0,009	10,939	496,2	219,1
Median	0,040	0,004	0,006	0,004	0,006	0,006	11,000	509	212
Variance	0,000	0,000	0,000	0,000	0,000	0,000	4,732	9404,7	4948,0
Std. Dev.	0,020	0,004	0,003	0,002	0,004	0,009	2,175	97,0	70,3
Std. Error	0,020	0,004	0,003	0,002	0,004	0,009	2,180	97,2	70,5
Minimum	0,002	0,002	0,001	0,003	0,002	0,003	7,000	115	62
Maximum	0,130	0,050	0,017	0,014	0,030	0,078	21,000	673	522
Range	0,128	0,048	0,015	0,011	0,028	0,075	14,000	558	460
Skewness	1,475	8,305	1,173	2,978	2,766	4,363	0,779	-0,874	0,740
Kurtosis	2,557	90,277	2,433	14,040	11,388	29,237	1,395	1,230	1,099
Shapiro-Wilk Normality Test									
W value	0,877	0,425	0,931	0,744	0,762	0,616	0,948	0,954	0,968
p-value	< 0,001	0,000	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
Wilks' Lambda MANOVA test									
Geological units									
F value	2,584	2,002	0,569	0,681	1,837	8,649	3,561	2,360	3,930
p-value	0,053	0,114	0,687	0,610	0,142	< 0,001	0,015	0,071	0,009
Soil taxonomy									
F value	0,574	0,481	0,575	0,698	0,047	10,234	0,406	0,371	0,933
p-value	0,568	0,622	0,567	0,503	0,954	< 0,001	0,669	0,692	0,402
Principal component analysis									
PC1	-0,270	-0,040	-0,264	0,119	0,349	-0,010	0,705	-0,641	0,780
PC2	0,730	0,120	-0,047	-0,091	0,013	0,616	-0,204	0,437	-0,034

Table 1 Continued - Summary statistics of the datasets, including the quantitative analysis of distribution, variance, error, and range. Results of Shapiro-Wilk and Wilks' Lambda statistical tests are described below, as well as the first two principal components.

	R	G	B	Si-O-Si (a.u.)	C=O (a.u.)	Si-O-Fe (a.u.)	Si-O (a.u.)	Si-O-Al (a.u.)	Si-O-Si (a.u.)
Descriptive statistics									
Average	332,6	181,3	116,9	0,132	0,004	0,068	0,074	0,111	0,237
Median	328	170	104	0,122	0,003	0,069	0,074	0,106	0,237
Variance	8893,0	5207,1	3174,9	0,003	0,000	0,001	0,001	0,002	0,005
Std. Dev.	94,3	72,2	56,3	0,054	0,005	0,024	0,023	0,043	0,074
Std. Error	94,5	72,3	56,5	0,054	0,005	0,024	0,023	0,044	0,074
Minimum	90	54	27	0,010	0,000	0,008	0,007	0,011	0,027
Maximum	675	508	394	0,340	0,047	0,142	0,133	0,262	0,474
Range	585	454	367	0,330	0,047	0,134	0,125	0,250	0,447
Skewness	0,314	1,083	1,629	0,846	4,112	0,122	-0,030	0,596	0,219
Kurtosis	0,132	1,809	4,097	0,954	22,451	-0,288	-0,141	0,415	0,265
Shapiro-Wilk Normality Test									
W value	0,990	0,937	0,878	0,957	0,581	0,996	0,996	0,978	0,993
p-value	0,117	< 0,001	< 0,001	< 0,001	< 0,001	0,738	0,773	0,001	0,390
Wilks' Lambda MANOVA test									
Geological units									
F value	3,179	4,868	4,655	0,473	0,549	1,597	0,708	0,463	0,821
p-value	0,024	0,003	0,004	0,755	0,701	0,196	0,592	0,762	0,520
Soil taxonomy									
F value	1,200	0,529	0,338	0,449	0,797	2,011	1,330	0,601	0,900
p-value	0,312	0,594	0,715	0,642	0,458	0,147	0,276	0,553	0,415
Principal component analysis									
PC1	0,687	0,850	0,874	0,750	-0,085	0,659	0,509	0,575	0,719
PC2	0,036	-0,111	-0,175	0,386	-0,324	0,661	0,713	0,683	0,553

As observed on the coefficient matrix (Figure 3) using Pearson's dissimilarity distance between sets of data, four major cluster groups were verified, with a consistent internal correlation: (a) a colorimetric cluster, which encompasses the red-green-blue indices, hue, and saturation, along with light elements (LE) and carbonyl band; (b) an ATR-FTIR group, mostly composed of the silicon (Si-O-) bands, also associated to the radiometric ^{40}K and ^{232}Th variables; (c) a predominantly geochemical category, which includes the Fe, Zn, Ti, V, Mn, Cu, and Ni parameters, in addition to MS and saturation index; and (d) a heavy metal group, which comprises the Zr, Nb, Pb, Bi, and ^{238}U .

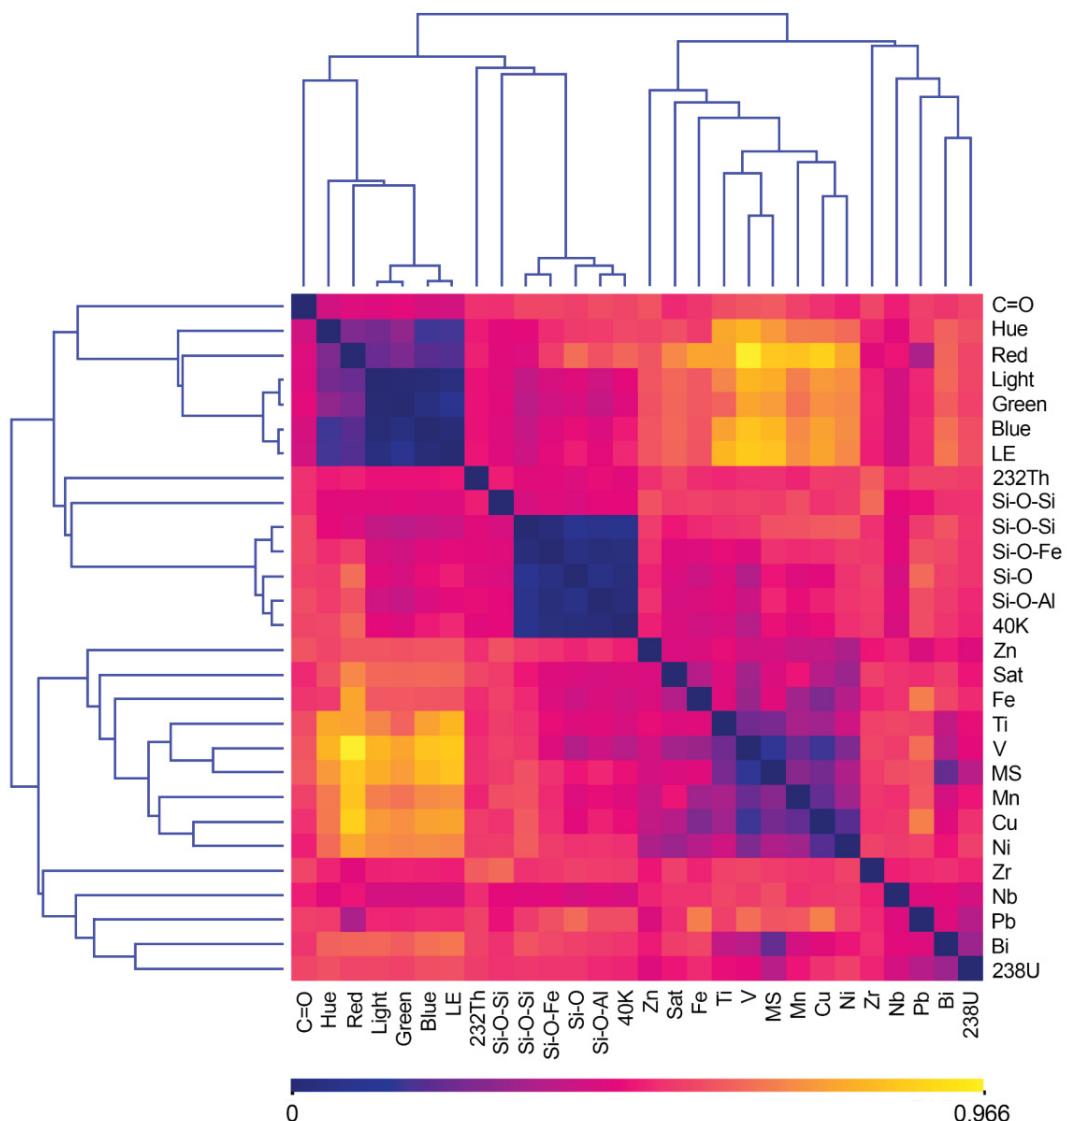
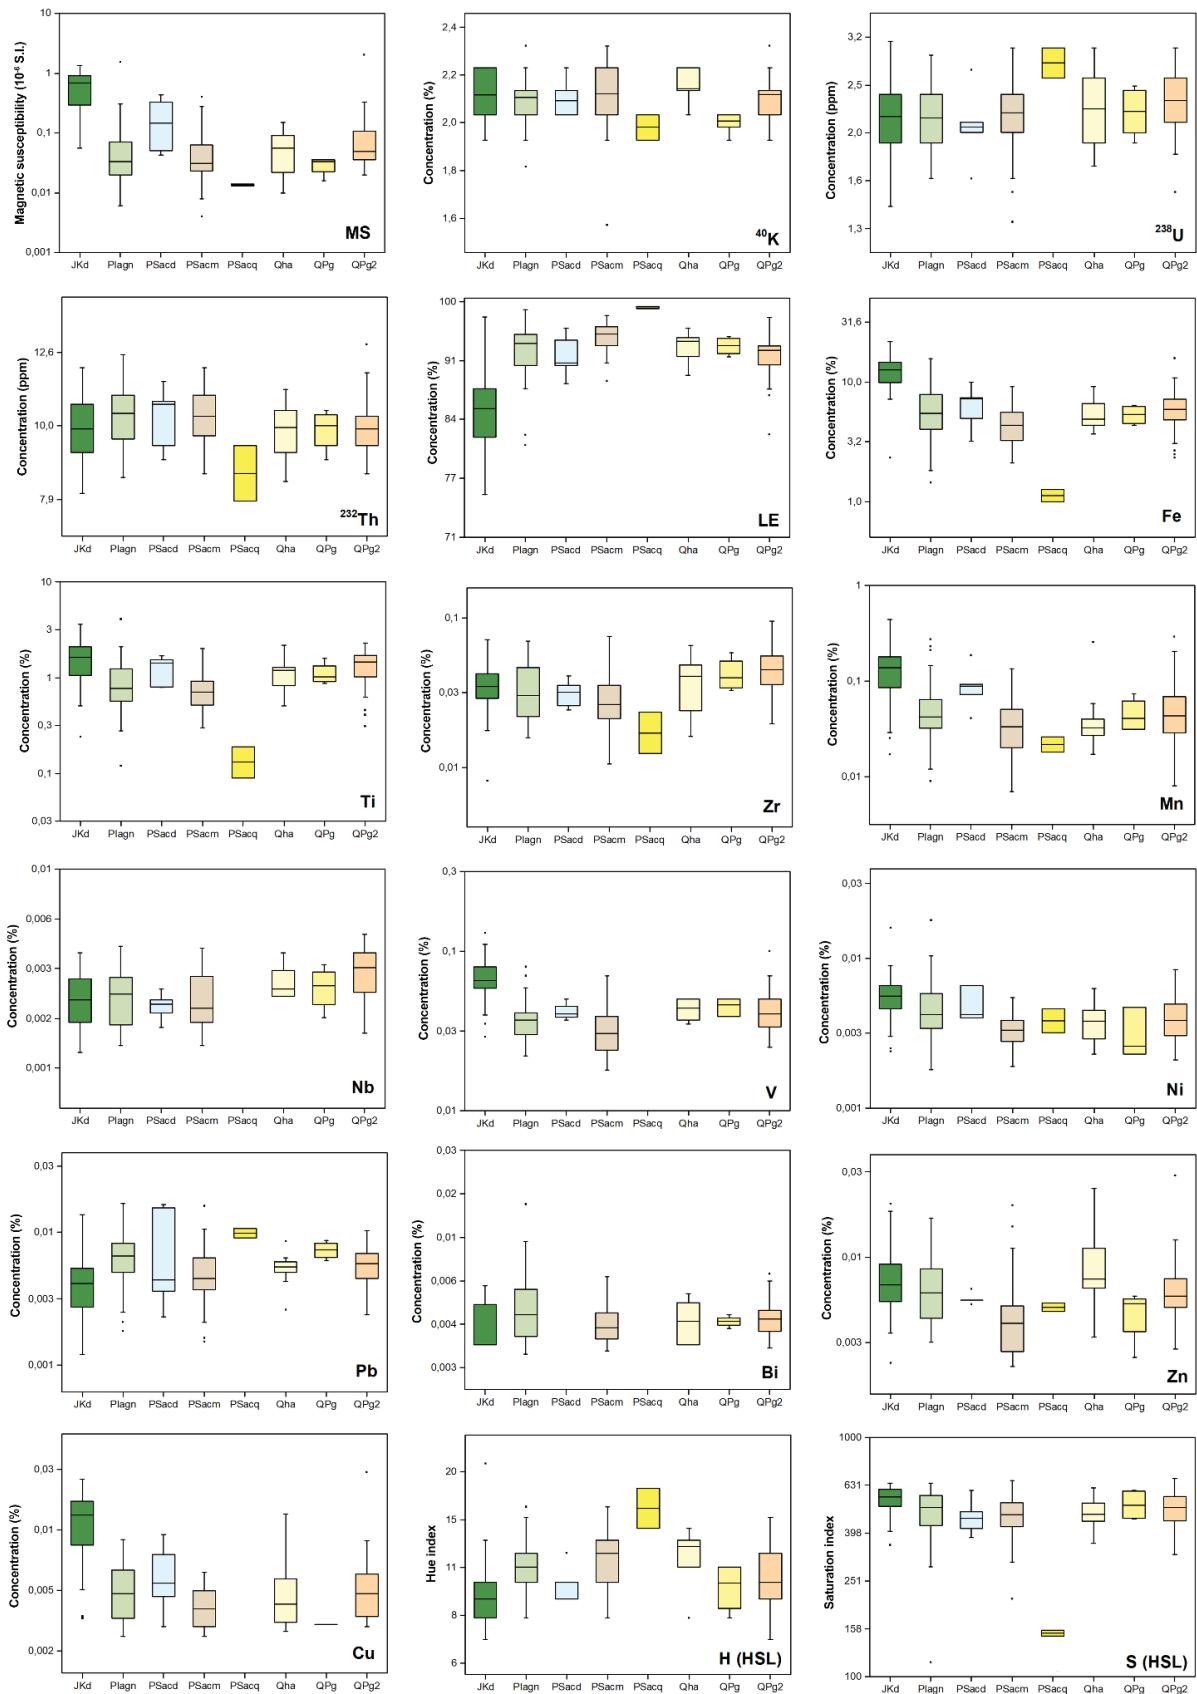


Figure 3 - Hierarchical clustering based on Pearson's dissimilarity distance for the retrieved variables. Heatmap ranges from zero (dark blue, highest correlation) to 0.966 (bright yellow, lowest correlation).

For pXRF data, a strong negative correlation (or high dissimilarity) was found between LE and Fe, and a moderate positive correlation between the latter and Cu, V, Mn, Ti, and color saturation. A weak (< 30%) linear dependency was verified between the radiometric and magnetic variables. Light elements and iron content also exhibit a positive and negative correlation with soil brightness, respectively.

3.2 Lithological signatures

Due to distinct lithostratigraphic classes, considerable compositional heterogeneity (Figure 4) was observed among the samples. Regarding geophysical parameters, a positive magnetic anomaly was found associated with the basaltic dykes (JKd). Not only MS, but this unit also represents the highest Fe-Mn-Ti-Cu-V values, corresponding to a geochemical association (for correlation > 0.60), and the lowest LE, typical attributes of soils derived from basic igneous rocks. In terms of color, its finer fraction samples are predominantly reddish (Figure 5), ranging from brown to dark red and reddish-yellow, reflecting in low RGB, lightness, and hue, and slightly higher saturation values. The sandy fraction, however, presented a dark to pale brown and grey colors, mostly influenced by the mafic assemblage, visually verified. Metamarbles (PSacd) presents the second highest MS average and is also highlighted by the distinctive Pb content. A trending color was not perceived, but a transition from dark- to yellowish-brown.



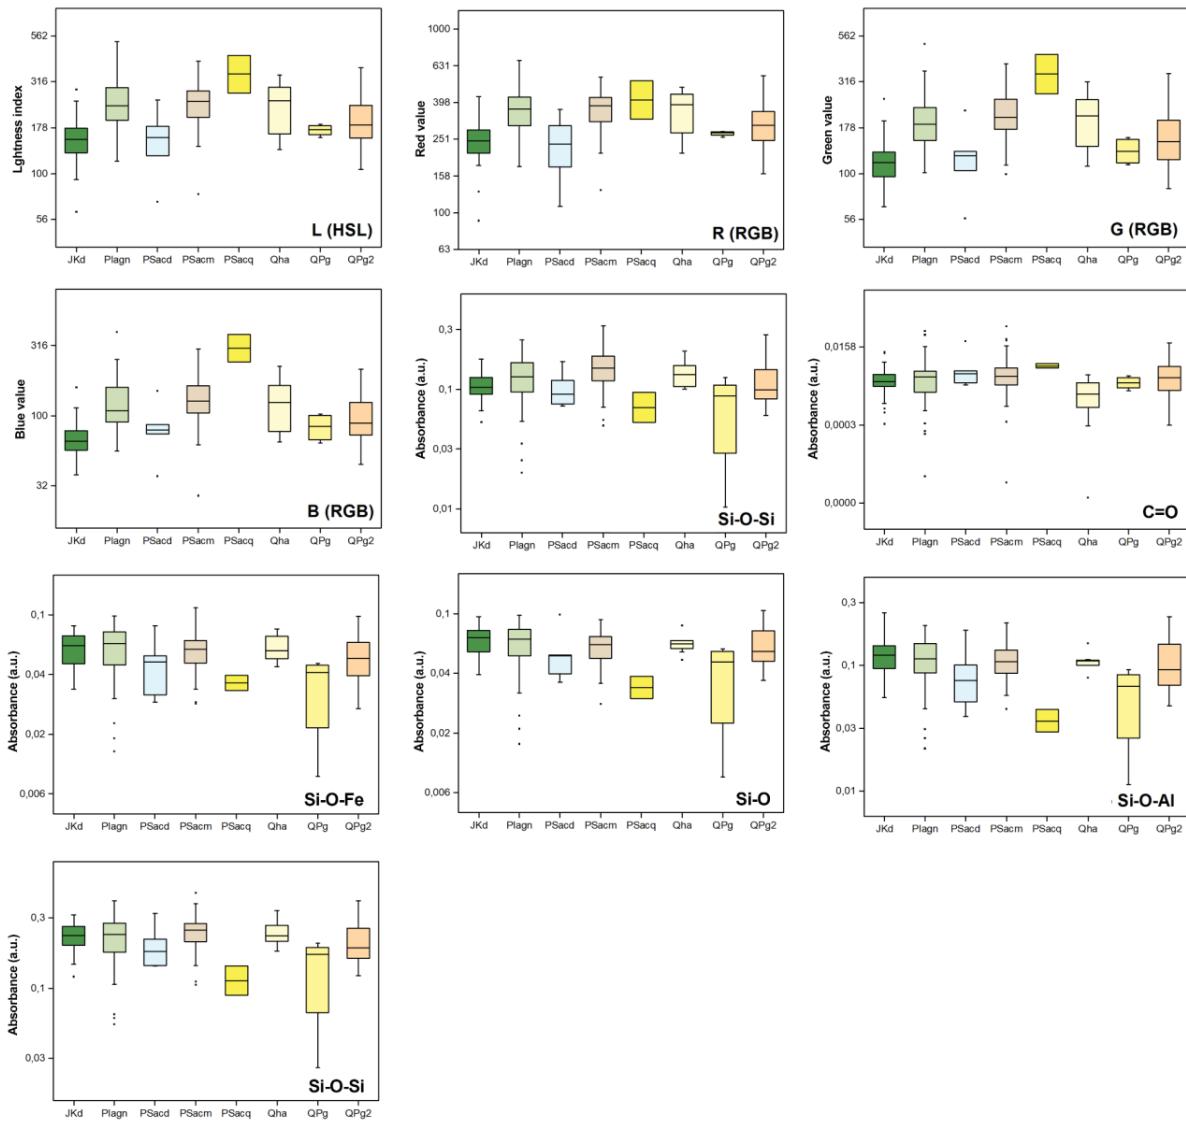


Figure 4 - Boxplot diagrams illustrating soil property variation in terms of parent rock. Interquartile range (IQR) is defined by the 25th and 75th percentiles and whiskers indicate the outliers beyond the 1.5 coefficient.

Neoproterozoic quartzites (PSacq), usually shaping resistant ridges and hilltops, have low MS signatures, which are mainly explained by the expressive amount of diamagnetic quartz (evidenced by LE > 98.5%), very few iron oxides (Fe < 1.3%), and low-grade metamorphism. A greyish color was observed for fractions II and III, confirmed by the superior lightness (L) and hue (H), and minor saturation (S) indices. Further interpretations are limited due to the small sample size ($n = 2$).

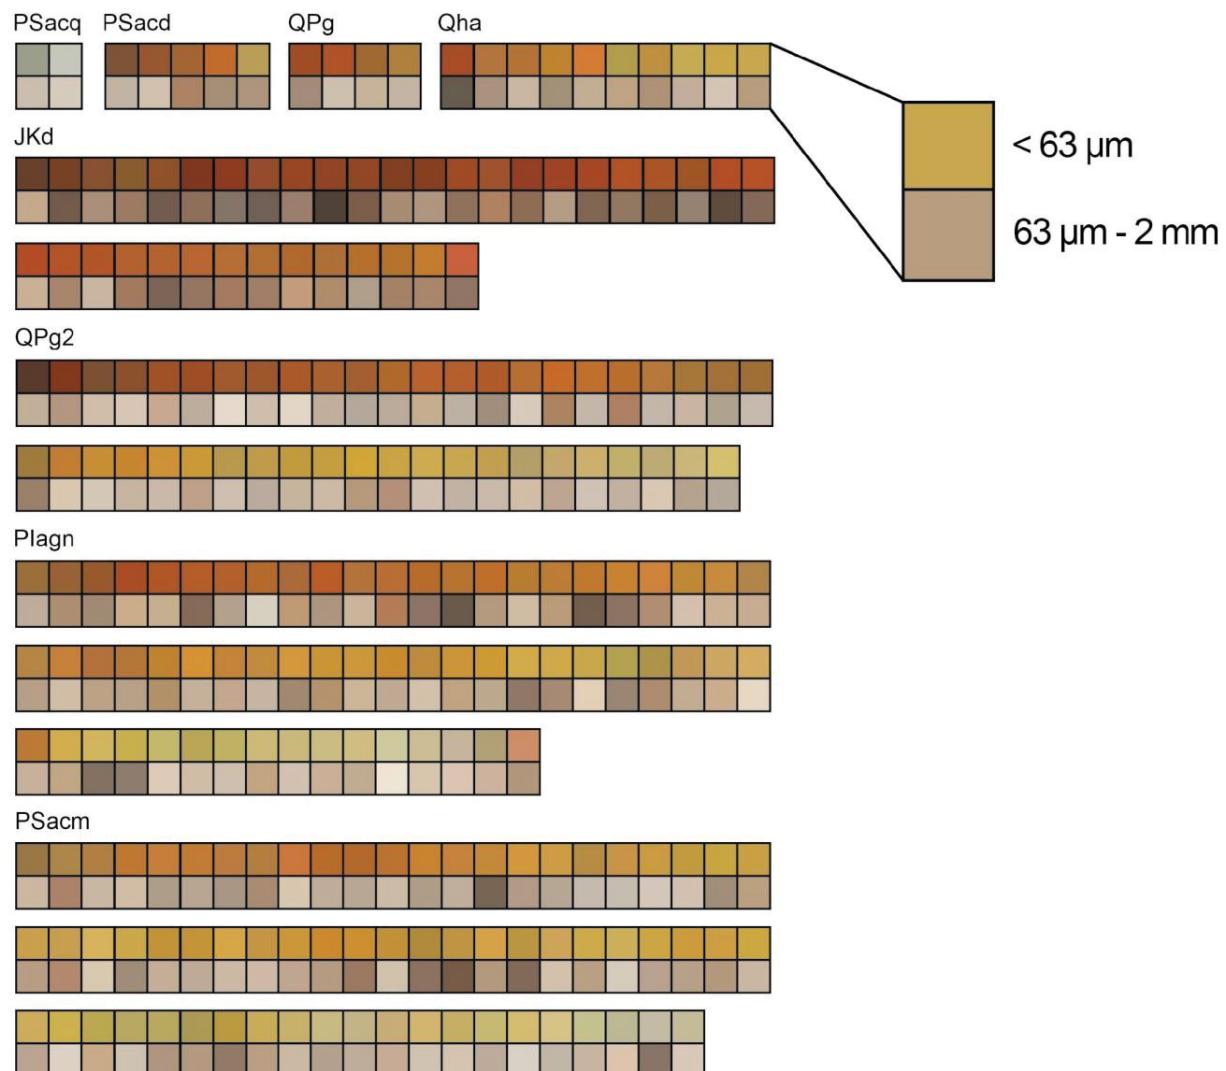


Figure 5 - Soil colors chart for the fine ($< 63 \mu\text{m}$) and the sand fractions ($63 \mu\text{m} - 2 \text{ mm}$), grouped by the geological units.

Soils developed above gneissic rocks presented slightly higher absorbance on the Si-O-Fe band (Figure 6) and bismuth (Bi) concentration above average. The $< 63 \mu\text{m}$ fraction comprises, in the majority of samples, goethitic specimens (yellowish colors) and, minorly, hematitic (reddish-brown). Fraction II (sandy) shows some dark grayish-brown individuals but is mostly characterized by light gray and pale brown members. Along with the metapelites (PSacm), these metamorphic units behave very similarly concerning heavy metals and geophysical properties.

In general, the sand, silt, and clay from the river banks deposits (Qha, QPg, QPg2) exhibit a modest increase above the overall Zr level. QPg2 unit also displays relatively high traces of Nb. Colors are partially reddish-brownish, as well as with shades of yellow.

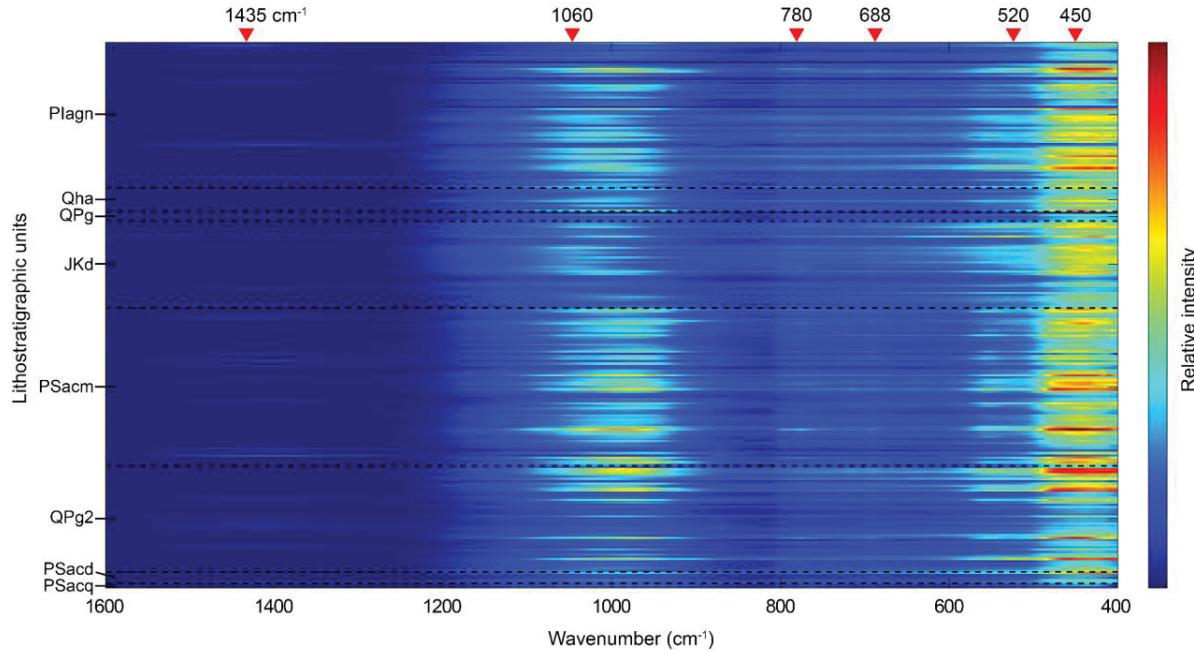


Figure 6 - ATR-FTIR spectra showing the retrieved peaks between the 400 and 1600 cm⁻¹ interval, stacked by the corresponding geological class. Heatmap illustrates the relative intensity of the absorbance (u.a.) for each sample individually.

3.3 Soil profile variability

Magnetic susceptibility (90%), Ni (80%), Cu (78%), Mn (76%), Fe (71%), LE (74%), and lightness index (69%) displayed the highest Pearson's correlation (Figure 7) between the top (< 5 cm) and the subsoil (B horizon). For instance, magnetic data revealed a significant trend in soils formed on igneous and metamorphic rocks. Profiles developed above the gneissic-migmatitic complex (Plagn) presented an upward enhancement, increasing the MS between 6% to 7 times the lower section. On the other hand, 6 out of 9 samples originating from tholeiitic basalt (JKd) showed a downward magnetization, intensifying 7 to 57%. Despite this, no clear tendency was observed in phyllite-controlled soils (PSacm). For the majority (70%) of soils that arose over unconsolidated sediments (Qha, QPg, and QPg2 units), surface samples have also shown an MS increase behavior when compared to the subsurface ones.

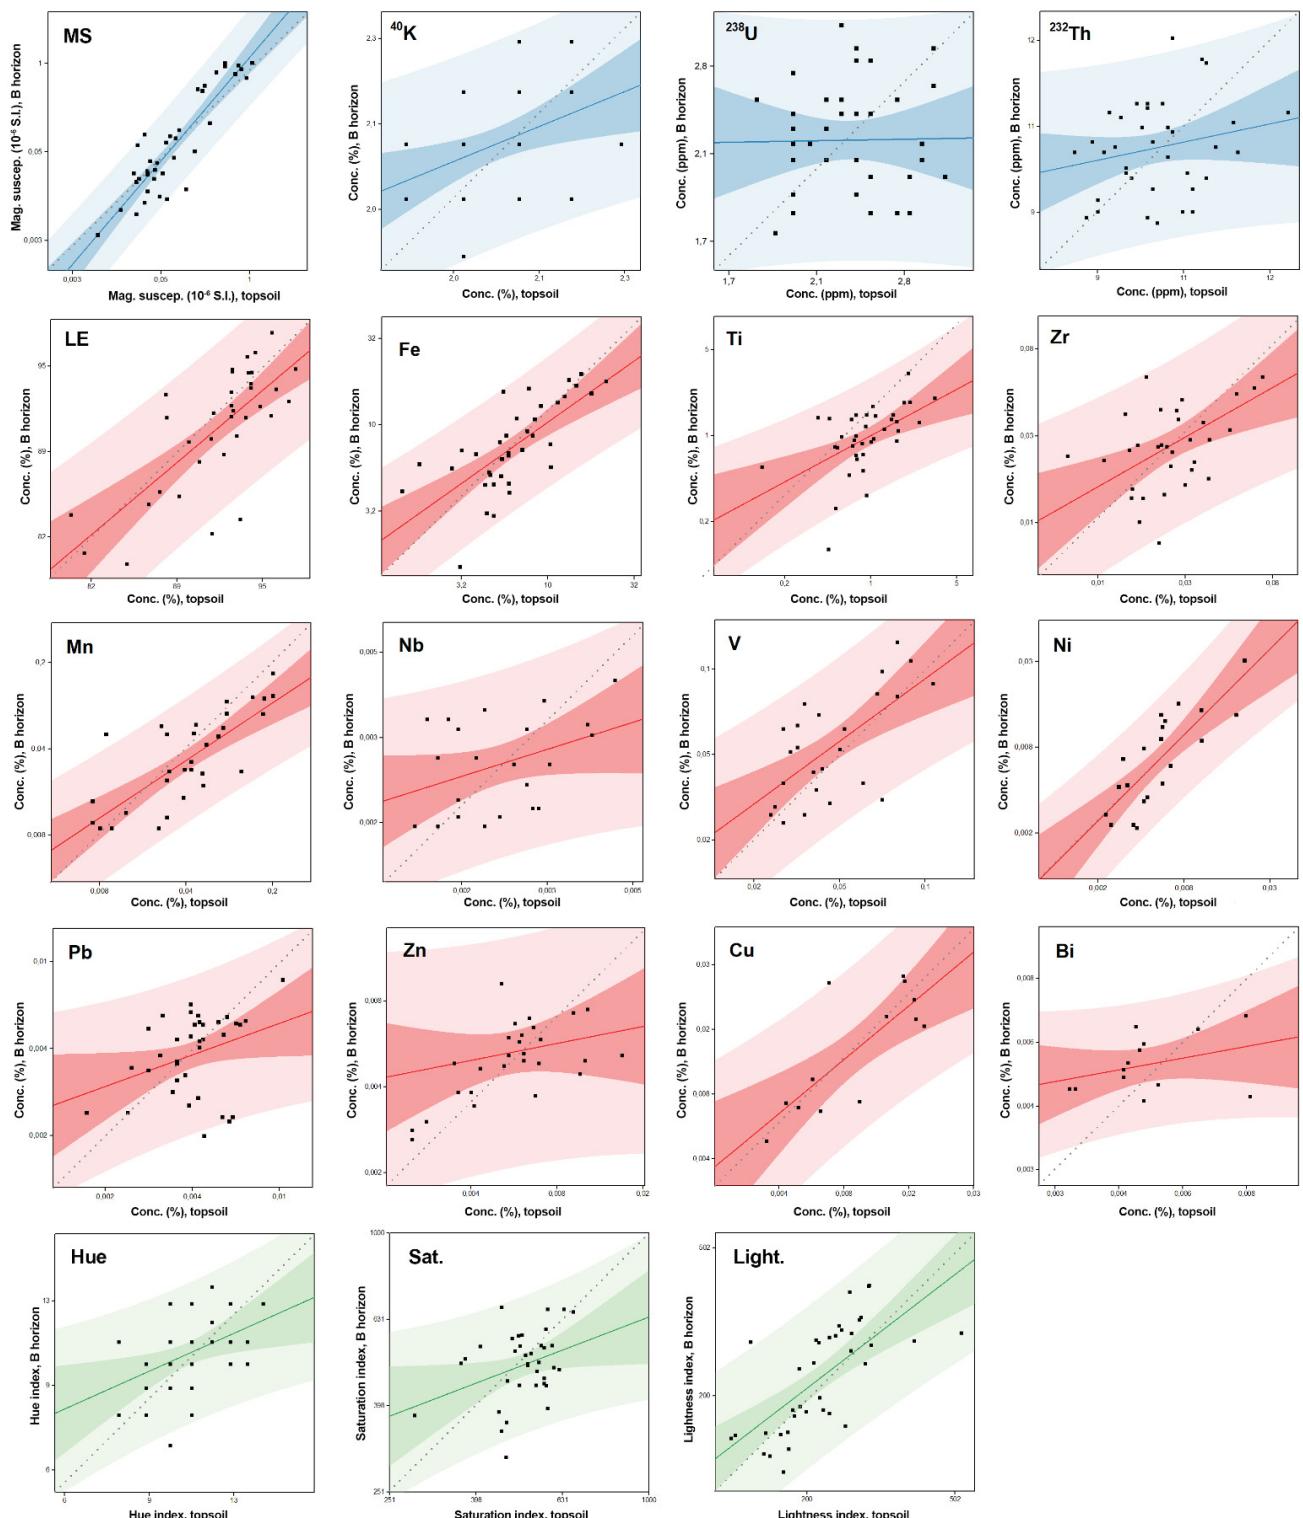


Figure 7 - Scatter plots with linear regression fits and the 95% prediction (light) and confidence (opaque) intervals, showing the relationship between the topsoil (< 5 cm) and the subsoil (B horizon) for the geophysical (MS and gamma-ray spectrometry), geochemical (pXRF) and colorimetric (HSL) parameters. Dashed gray lines indicate the $y = x$ function (45°).

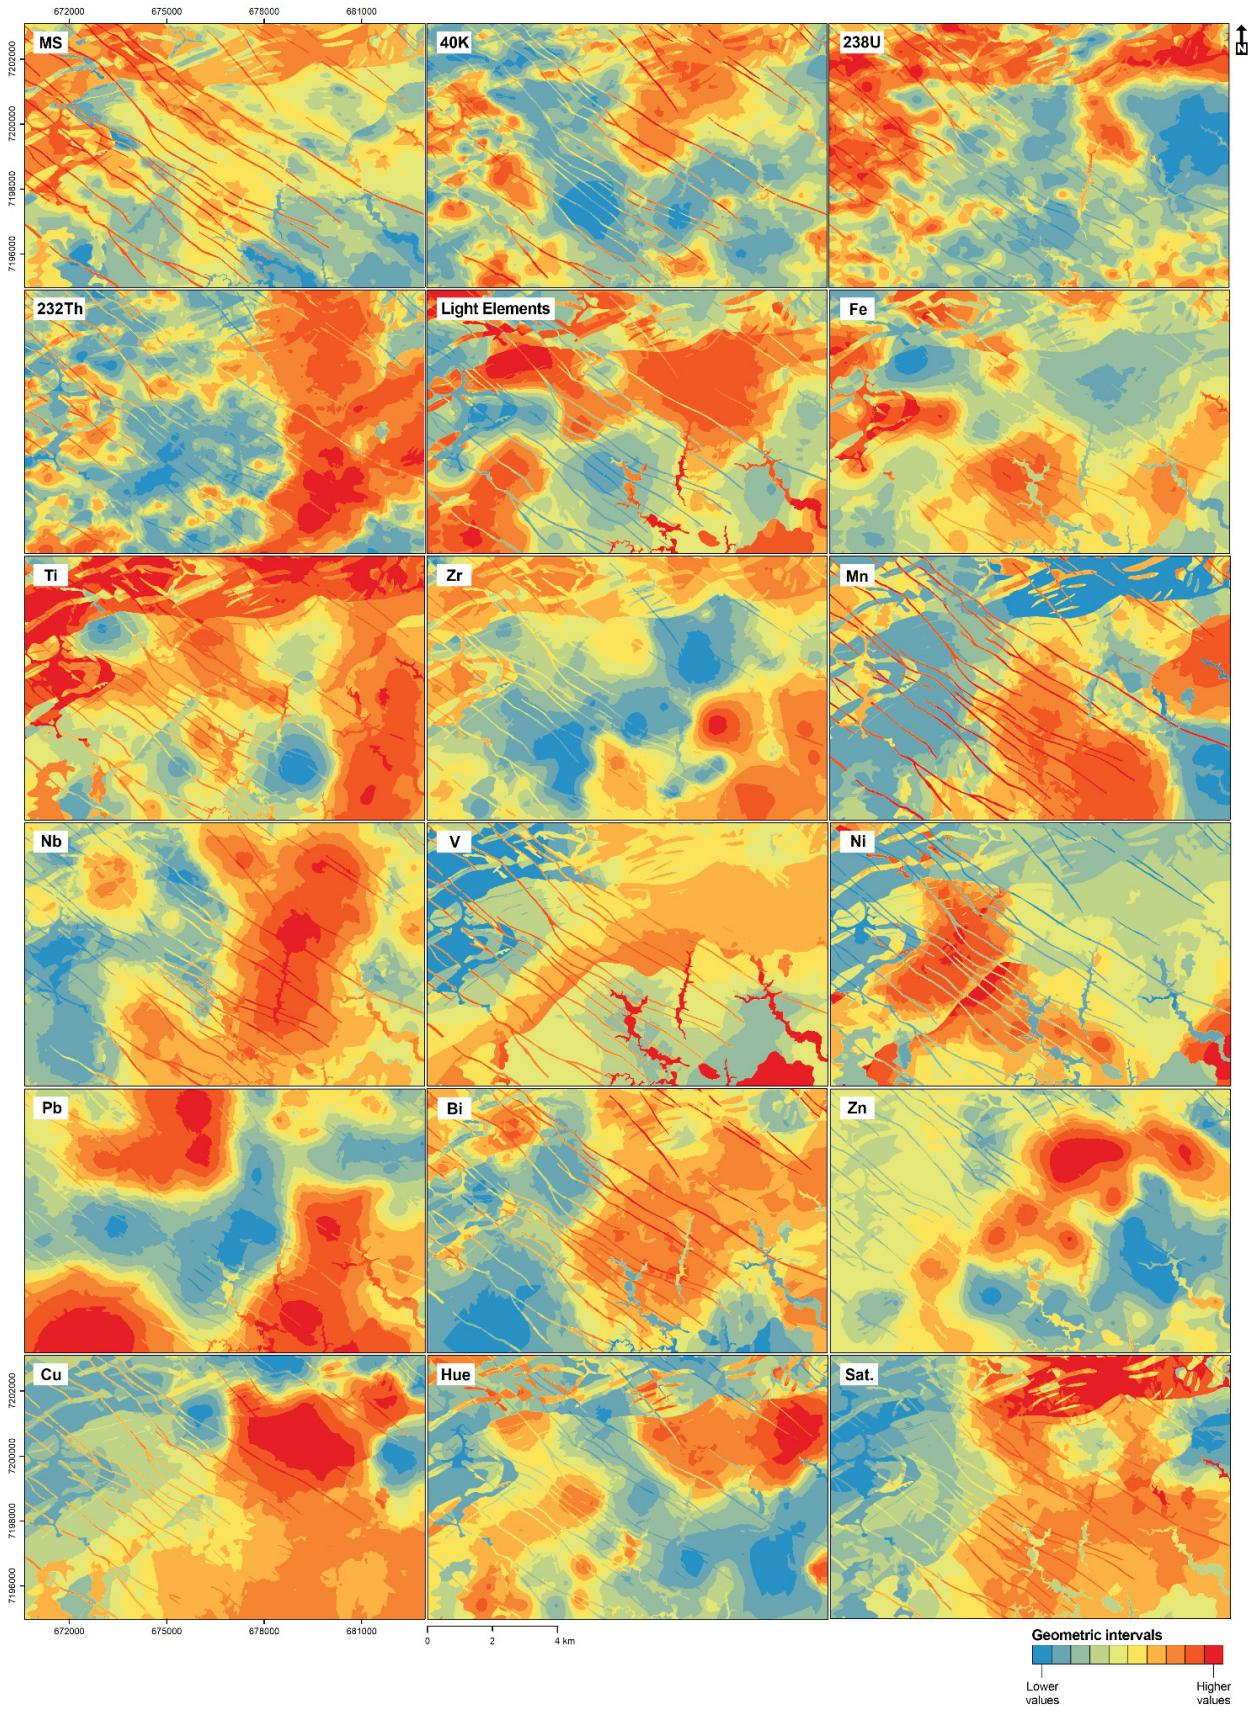
In terms of activity concentration of natural radionuclides (^{238}U , ^{40}K , and ^{232}Th), distributions were random and lithological clustering was not observed. However, ^{238}U presented the highest vertical migration, with an average variance of 25%, in contrast with 11% of ^{232}Th , and 5% of ^{40}K , the ones with the lowest mobility.

Light elements (LE) content indicates no overall trend of concentration (2%) in any of the soil layers, since it is more pronounced in the topsoil interval of the Plang (1 to 11%) and JKd (up to 12%) units and more homogeneous (roughly equivalent, on average) in the Quaternary sediments group (Qha, QPg, and QPg2) and PSacm (no more than 5%). Iron, nonetheless, brings up an exactly opposite behavior, inversely proportional to LE, having the highest downward enhancement in the gneissic-formed soils. Titanium and zircon were found to be more concentrated at deeper horizons on igneous and metamorphic rocks – in contrast with the alluvial sediments, where the majority of sampling sites (90%) shows a concentration of those elements in the topsoil. Retrieved data failed to address any remarkable trend regarding the remaining metals (Mn, Nb, V, Ni, Pb, Bi, Zn, and Cu).

Regarding colorimetric attributes, samples from the metapelitic unit became brighter in the B horizon, reflecting on higher values of L, R, G, and B. Concerning the other lithological classes, these colorimetric indices acted in a non-uniform way, just as saturation and hue.

3.4 Modeling uncertainty

The most accurate prediction model (Figure 8) was produced for the light elements (LE) variable, with a relative root-mean-square error (RRMSE) of 1.0% (Table 2) and a root-mean-square standardized error (RMSSE) of 0.99, followed by ^{232}Th (RRMSE = 3.8%; RMSSE = 0.98), ^{40}K (RRMSE = 6.8%; RMSSE = 0.94), and Pb (RRMSE = 8.1%; RMSSE = 0.94). Along with R, G, and the HSL indices, those models achieved an excellent accuracy (RRSME < 10%) (Li *et al.*, 2013). For the Zr, B, ^{238}U , Si-O, Si-O-Fe, Si-O-Al, C=O, and Si-O-Si variables, therefore, a good accuracy was obtained (10% < RRMSE < 20%), and a fair one (20% < RRMSE < 30%) for Fe, Zn, and O-Si-O. The EBK algorithm failed to successfully model (RRMSE \geq 30%) the MS, Ti, Mn, Nb, Ni, Bi, and Cu variables.



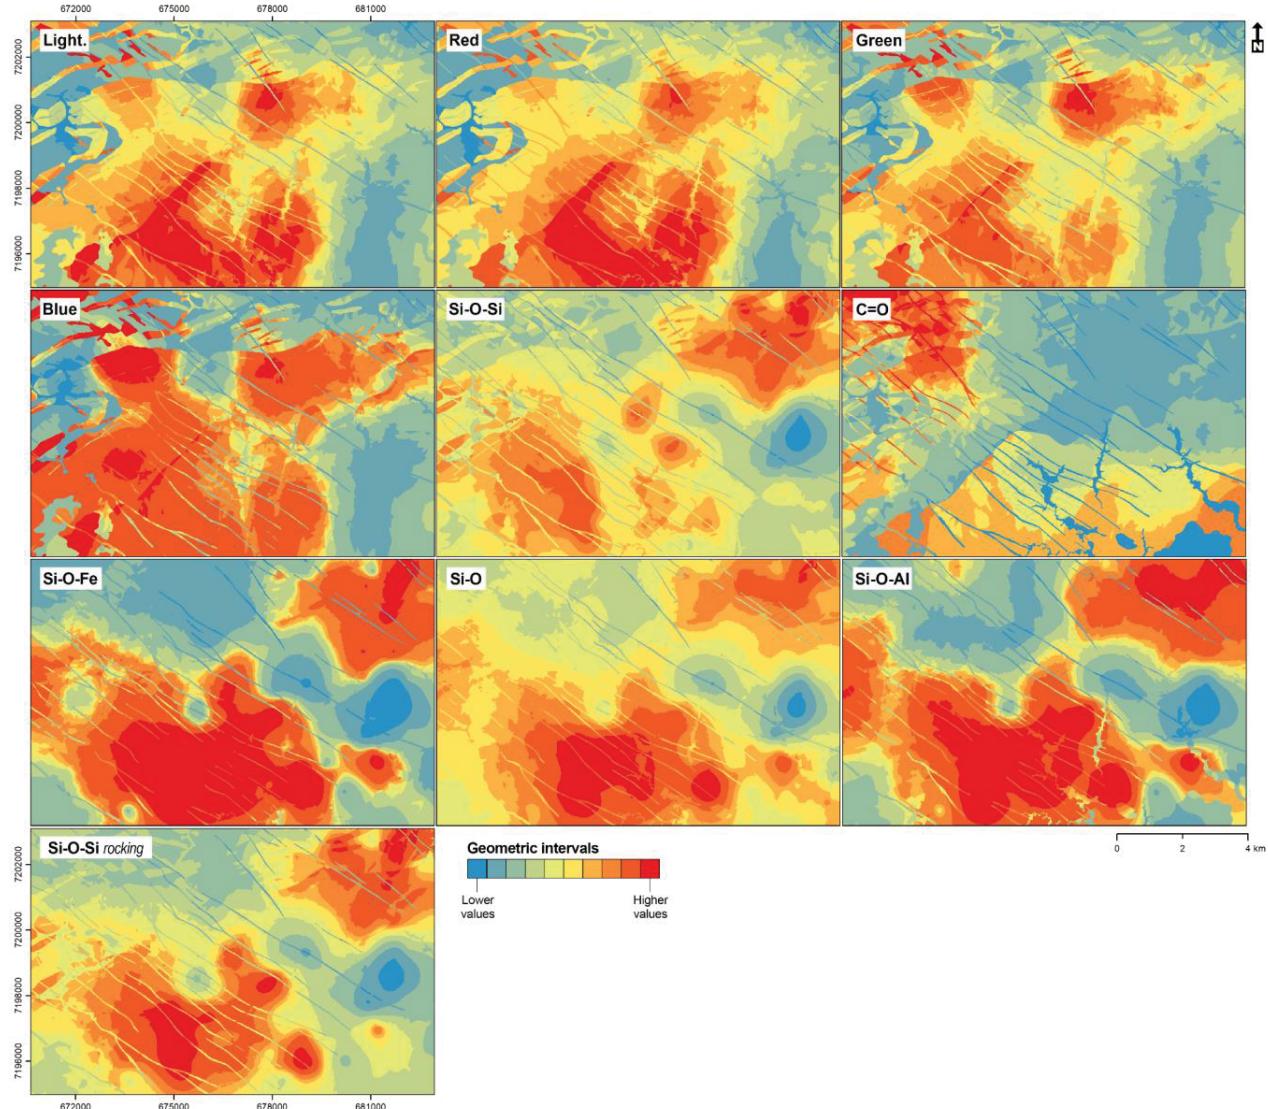


Figure 8 - EBK regression prediction models for the 28 variables in the dataset. Each raster is reclassified into 10 geometric intervals, ranging from the lowest (blue) to the highest values (red).

Table 2 – Cross-validation results and measurement errors for the EBK geostatistical models according to each variable. CRPS: average Continuous Ranked Probability Score; 95th: percentage of points that are in the 95% cross-validation confidence interval; RRMSE: relative root-mean-square error; RMSSE: root-mean-square standardized error; ASE: average standard error.

Variable	CRPS	95th (%)	RRMSE (%)	RMSSE	ASE (log)	Variable	CRPS	95th (%)	RRMSE (%)	RMSSE	ASE (log)
MS	0,28	93,3	42,7	0,97	0,52	Zn	0,29	95,1	26,1	0,90	0,63
⁴⁰ K	0,01	96,4	6,8	0,94	0,02	Cu	0,61	100,0	48,3	0,98	1,06
²³⁸ U	0,04	95,1	19,3	0,98	0,07	H	0,05	96,9	9,9	1,01	0,10
²³² Th	0,02	96,9	3,8	0,98	0,04	S	0,08	96,4	8,2	0,98	0,20
LE	0,01	93,8	1,0	0,99	0,02	L	0,09	96,0	8,7	1,03	0,19
Fe	0,12	95,1	27,5	0,97	0,22	R	0,09	96,9	8,2	1,02	0,19
Ti	0,13	95,1	779,0	0,99	0,24	G	0,10	96,0	9,6	1,02	0,21
Zr	0,10	96,0	12,2	0,98	0,19	B	0,11	96,0	10,9	1,03	0,21
Mn	0,22	95,1	30,7	0,94	0,42	Si-O-Si	0,10	95,5	19,3	0,94	0,19
Nb	0,61	94,6	41,6	0,96	1,13	C=O	0,25	94,6	18,6	1,00	0,48
V	0,33	99,1	42,3	0,94	0,62	Si-O-Fe	0,08	96,0	13,0	0,94	0,16
Ni	0,51	90,2	38,6	0,96	0,95	Si-O	0,08	95,1	12,5	0,93	0,16
Pb	0,10	96,0	8,1	0,94	0,19	Si-O-Al	0,09	96,4	17,1	0,95	0,18
Bi	0,68	100,0	48,3	0,97	1,19	Si-O-Si	0,08	96,0	21,9	0,94	0,15

3.5 Provenancing scores

3.5.1 The Search Range method

Considering four geometric interval classes for the cumulative boolean rasters, the Search Range (SR) method (Figure 9) was able to perfectly ‘match’ (contained within the superior class) 4 out of 14 validation samples (Table 3), excluding 67.7 to 97.5% of the original area (100 km²). Less accurately, 5 samples match only at the second class, excluding 29.9 to 60.2% of the total area. Moreover, 3 out of 14 were held in the third most probable prediction class, allowing to eliminate 3.2 to 33.7% of the search perimeter. At last, the SR method failed to address a minimum range of provenance for 2 of the validation samples.

Taking into account each variable individually, the most successful prediction satisfied 20 out of 21 attributes (95.2%). In some circumstances, the target samples stayed beyond the upper and lower boundaries of the database, returning null outputs for the SR equation. That specific situation happened constantly for the Nb, V, Bi, and Cu variables, which may be related to its flawed geostatistical models, as previously

mentioned. On the other hand, Pb, Zr, Si-O-Si, and C=O stood out as the most assigned variables ($\geq 10/14$ samples).

Table 3 - Overall provenancing scores for the Search Range (SR) and the Euclidean distance (ED) prediction methods, indicating the excluded area rate (in %) for each validation sample, including the number of variables satisfied during the SR function and the ED to the nearest sampled neighbor.

Validation Samples	Search Range (SR)			Euclidean Distance (ED)		
	Class	Excluded area (%)	Variables satisfied	Class	Excluded area (%)	ED to closest point (%)
1S	2nd	60,2	6 out of 9	1st	61,7	65.0
2S	1st	97,5	7 out of 8	3rd	0	34.4
3S	3rd	33,7	6 out of 9	1st	57,2	68.9
4S	2nd	29,9	7 out of 12	1st	63,4	77.9
5S	3rd	3,2	3 out of 7	2nd	39,7	53.0
6S	2nd	57,9	12 out of 17	1st	62,8	81.8
7S	1st	67,7	20 out of 21	1st	55,0	73.7
8S	1st	83,9	18 out of 20	1st	60,9	82.4
9S	4th	0	11 out of 21	2nd	45,1	79.6
10S	2nd	57,4	9 out of 20	3rd	0	21.5
11S	2nd	37,2	8 out of 16	2nd	29,6	60.3
12S	3rd	11,1	14 out of 19	1st	56,5	76.9
13S	4th	0	14 out of 21	2nd	35,1	78.4
14S	1st	78,1	11 out of 15	1st	59,3	88.6

The second most accurate prediction achieved a score of 18 out of 20 variables (90.0%), followed by 7 out of 8 (87.5%). In the opposite way, three validation samples satisfied less or equal than half of the valid parameters, summing up 3 out of 7 (42.9%), 9 out of 20 (45.0%), and 8 out of 16 (50.0%).

The magnitude of exclusion for each variable can be adjusted by leveling the confidence interval on the SR equation. By selecting a higher amplitude, the resulting search area gets wider and the inquiry becomes impractical – however, it minimizes the chances of null outputs, and vice-versa. In this study, the 0.5, 1, 1.5, and 2.0 values of standard deviation were tested, but the ± 1.0 STD gap was hand-picked as the most suitable threshold.

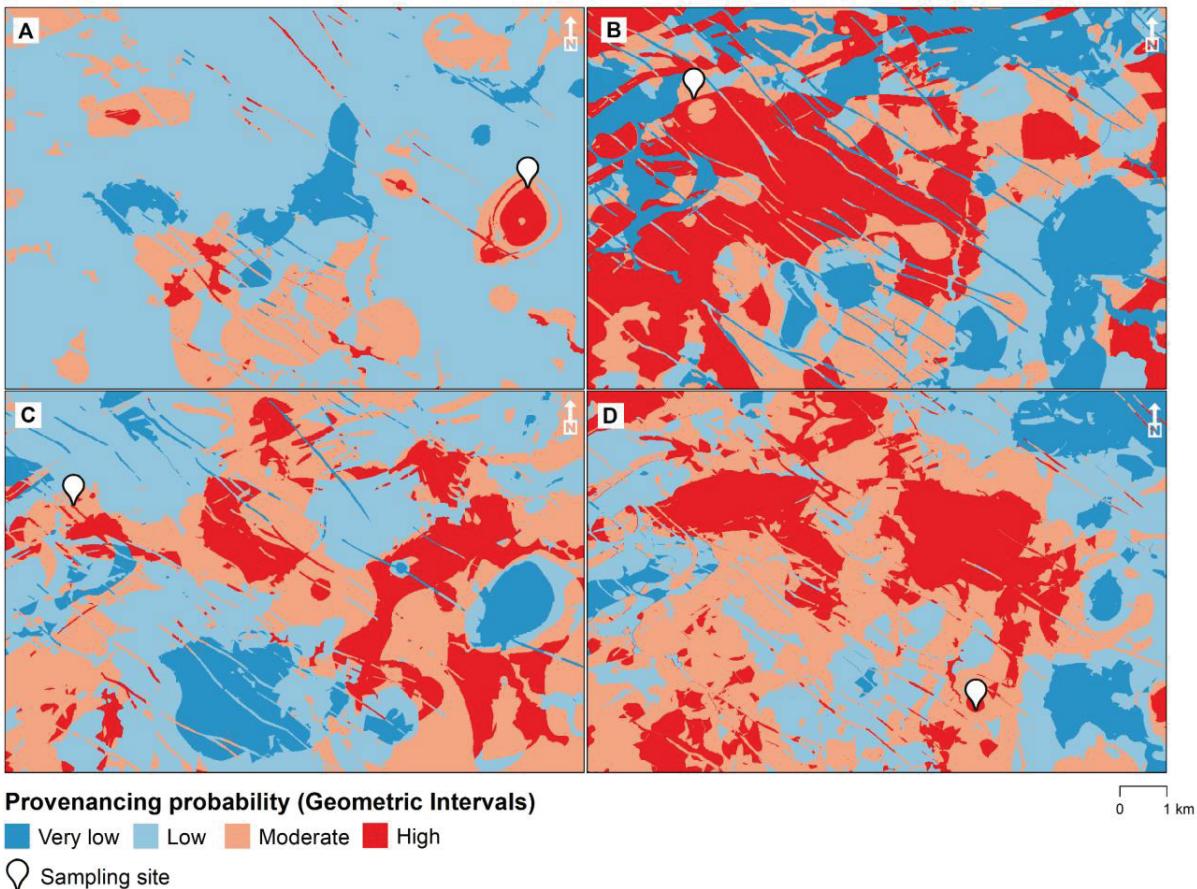


Figure 9 - Prediction results for the 2S (A), 7S (B), 8S (C), and the 14S (D) validation samples, when applied the Search Range (SR) method. Prediction classes vary from the least (blue) to the most probable (red) sites of origin.

3.5.2 The Euclidean distance method

With respect to the performance scores of the Euclidean distance (ED) method (Figure 10), the source of 8 out of 14 samples was correctly estimated, which corresponded to the top one-third of the natural break classes, and stood in a short gap between 63.4 and 55.0%. The secondary outcomes (4 out of 14), lastly, managed to eliminate from 45.1 to 29.6%. The most striking results for pairs of samples were observed in the validation aliquots 14S and 6S, leading to an 88.6 and 81.8% of similarity with the nearest sampling point of the database, respectively, indicating a great discriminatory power in close-proximity sites. Two samples resulted in null outputs and failed to point out a provenance region, which resulted in similarities of 21.5 and 34.4% with its corresponding neighbors.

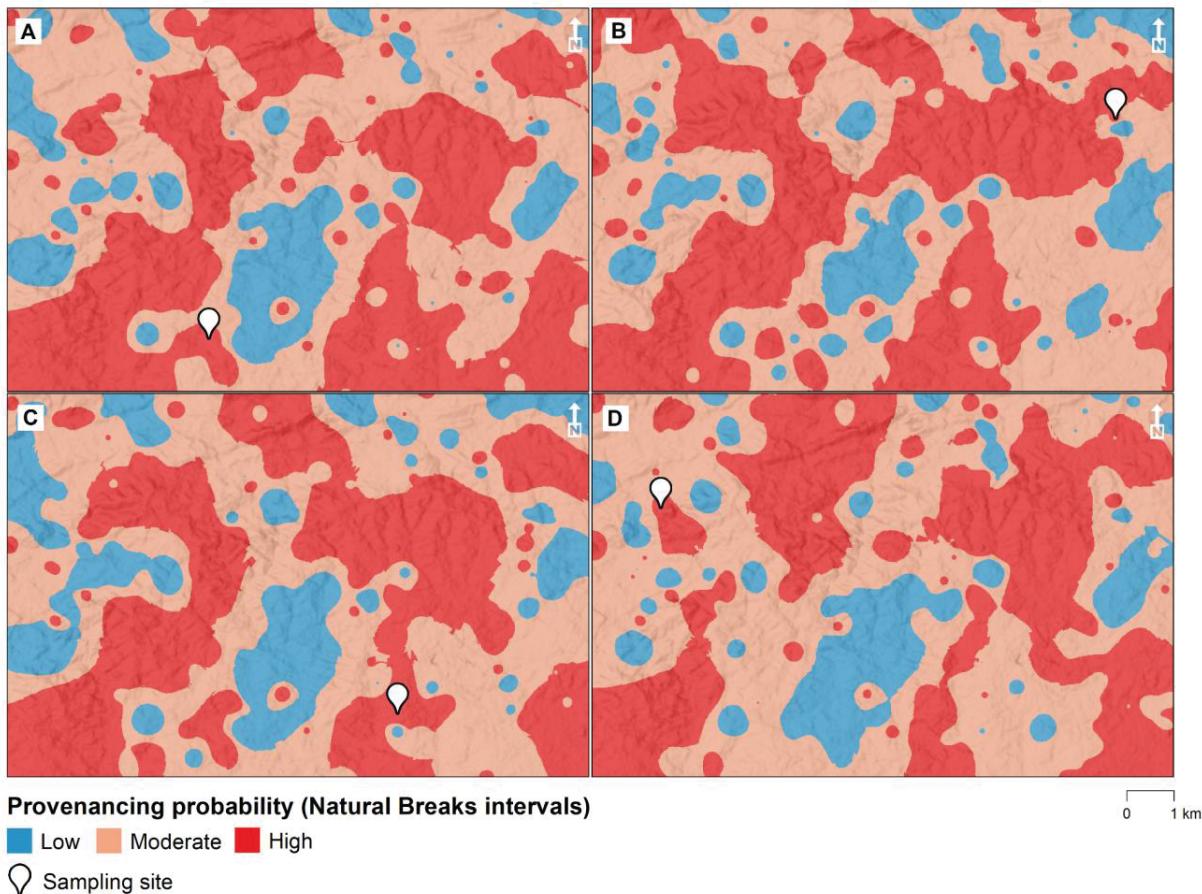


Figure 9 - Prediction results for the 12S (A), 3S (B), 14S (C), and the 8S (D) validation samples, when applied the Euclidean distance (ED) method. Prediction classes vary from the least (blue) to the most probable (red) sites of origin.

4. DISCUSSIONS

4.1 Lithological control on soil composition

Even though climate, biota, topography, and time have a big effect on pedogenesis, data (Figure 4) has shown that parent rock strongly influences some of the measured topsoil properties. The most distinguishable feature of the volcanic unit (JKd), the magnetic susceptibility, also takes part in the discriminant power of its surrounding rocks, probably on account of percolating magmatic fluids (Sparks *et al.*, 2019) and the presence of Fe- and Mg-rich minerals. By considering the iron abundance (Table 1) and reddish color (Figure 5) of these soils, one may assume the presence of ferric oxides and

hydroxides, such as hematite, ferrihydrite, and maghemite. However, X-ray diffraction data is needed to confirm such a hypothesis.

Metamarbles (PSacd) relatively high magnetization, in its turn, may be accounted to differential weathering, such as leaching of soluble calcium carbonate and authigenic formation of ultrafine-grained ferrimagnetic minerals, both single-domain (SD) and superparamagnetic (SP), giving rise to *in situ* remagnetizations (Jackson & Swanson-Hysell, 2012; Maher & Taylor, 1988), even when iron oxides concentrations are low – however, deeper studies are required to clarify those statements. Regarding its above-average lead content (Figure 4), it may be assigned to fixation processes at high pH in calcareous soils (García-Delgado *et al.*, 1996).

Under specific thermodynamic (T-P) and oxidation/reduction conditions, hematite-bearing sediments can trigger the production of magnetite and, therefore, increase hosts MS (Clark, 1997; Pilchin, 2011), which was not observed in the low-grade quartzites (PSacq).

4.2 Depth dependence of soil properties

The vertical variability of the measured soil attributes in soil (chemical, colorimetric and geophysical) is mainly guided by the solubility and stability of cations at specific oxidation and pH conditions of the soil. Ions of extreme ionic potential tend to dissolve into soil aqueous solution and are leached and carried away by groundwater, such as molybdate (Mo^{+6}), chromate (CrO_4^{-2}), and phosphate (PO_4^{-3}) (Railsback, 2003). Some elements such as Fe(III), Mn, Cu, and Ni of intermediate ionic potential, on the other hand, present low solubility in acid soils and are commonly found composing oxides and hydroxides in residual topsoil, with relatively less mobility - which was verified by the higher Pearson's correlation in the soil profiles (Figure 7). Due to their considerable vertical stability, these metals may be preferred for topsoil (< 5 cm) property predictions. In the current soil database, these metals, along with MS, LE, and lightness index, also presented a high correlation to the first principal component (PC1), suggesting a greater provenancing potential.

Magnetic susceptibility (MS) presented either a top- or a subsoil enrichment, depending on the parent material. The first situation, related both to the gneissic (Plagn)

and sedimentary (Qha, QPg, and QPg2) units, may be explained by the pedo- and biogenic formation of secondary iron-bearing magnetic oxides, such as microcrystalline maghemite ($\gamma\text{-Fe}_2\text{O}_3$) or magnetite ($\text{FeO} \cdot \text{Fe}_2\text{O}_3$) via oxidation-reduction cycles, especially in the finest grain sizes (< 0.04 μm) (Shenggao, 2000; Szuszkiewicz *et al.*, 2021). The second condition, in turn, which embraces the volcanic-derived soils (JKd), can be associated with the weathering of primary magnetic minerals in the uppermost layer, leaving the inherited ferrimagnetic matter in the deeper and less evolved horizons (Lu *et al.*, 2008). These phenomena corroborate the premise that both climate and bedrock play a big role in managing the vertical distribution of many soil properties (Rawlins *et al.*, 2003; Taghdis *et al.*, 2021).

Under acid soils, such as the ones present in the study area (pH 4.3 - 5.3, according to IBGE, 2016), uranium is significantly more soluble and has greater mobility than thorium, which is corroborated by the higher migration behavior of ^{238}U in the soil profile, as observed in the database samples and endorsed by published literature (Rodríguez *et al.*, 2012).

Throughout the whole sampling area, light elements (LE) were most abundant in the shallower soil levels, which can be attributed to hydrolysis of the unstable primary assemblage, such as pyroxenes, amphiboles, and mica, and enrichment on secondary minerals, commonly quartz and aluminosilicates, following Goldich's weathering series. In the silicon-rich alluvial sediments, zirconium and titanium concentration in the uppermost horizon may indicate the presence of residual weathering-resistant ultrastable heavy minerals, such as zircon, ilmenite, and rutile (McBride, 1994).

Soil surveys in Brazil, mostly conducted by government agencies, currently count with more than 100,000 soil samples collected from the B horizon and spread all over its territory, gathering geochemical data produced by XRF, AAS, ICP-MS, ICP-AES, colorimetry, and many other techniques. Originally conceived for mineral exploration purposes, those datasets might be useful for forensic provenancing, as long as it supports the prediction of topsoil (< 5 cm) composition.

4.3 Spatial modeling

Since Empirical Bayesian Kriging (EBK) regression predictions are based on explanatory variables, the model performance depends greatly on the quality of the selected datasets and their relationship with the dependent variable. In the case of nonlinear correlation between each pair, biasing can substantially influence the forecast function.

Even though the EBK regression prediction method did not achieve, generally, perfect results in the cross-validation test (Table 2), the models took into account the geological settings and managed to interpolate different subsets inside each lithostratigraphic feature. Units with narrow geographic coverage, usually arranged as thin sheet-like bodies, such as the basaltic dykes (JKd) and metapsammites lenses (PSacq), are commonly disregarded during interpolation processes. Once the contacts are abrupt, i.e. boundaries between carbonates (PSacd) and alluvial sediments (Qha), barriers may be suitable to correctly delineate these changes (Figure 8). During a forensic soil provenancing investigation, such misrepresentations can hide the true source of a questioned sample, if it belongs to a unit not covered by the soil survey.

4.4 Overall provenancing evaluation

Although the ED method provided more samples in the first class (*8 versus 4*), the average area exclusion rate was significantly lower than that of SR (81.8 against 59.6%), including the three samples that matched in both sourcing algorithms (Table 3). Nevertheless, for validation samples that fell in lower provenance probability classes for SR, ED performed slightly better (37.4 vs. 33.3%, on average).

The Search Range (SR) protocol (Figure 9) had the advantage to take into consideration the lithological aspects of the terrain since it was based on the EBK regression prediction, using geological and geophysical maps as explanatory rasters – unlike the Euclidean distance (ED) method (Figure 10), which was entirely based on a deterministic interpolation approach, less influenced by the physical and chemical signatures of the parent rocks and its boundaries. For this very reason, SR also inherited

a much significant error associated with the geostatistical model, evidenced by the RRMSE and RMSSE values.

Notwithstanding, both methods face the limitations and inaccuracy of the non-destructive analyses and the sample treatment itself applied to build the database. Portable X-ray fluorescence (pXRF), despite being reliable and low-cost, usually presents many issues regarding its functionality and results may be heavily biased depending on the sampling, analysis, and material conditions (Bergslien, 2019). Since soil color analysis was performed after ignition (at 650 °C) for OM removal, it suffered major structural changes in oxides and clay minerals. Hence, reddening was observed in some yellowish inorganic samples after heating, indicating the dehydration of goethitic compounds to hematite at ~270°C (Ruan *et al.*, 2002). The transformation sequence includes maghemite or single-domain magnetite production at heating above 450 °C (Minyuk *et al.*, 2011). Given that every sample was submitted to the same treatment protocol, despite visual OM content, this particular issue was minimized – but variability reduction could not be avoided.

The hand-held gamma-ray spectrometer used in this survey has an extremely sensitive detector for environmental interferences, whose accuracy is subject to many technical aspects, including the statistical nature of radioactivity, the influence of background radiation from atmospheric radon, soil moisture, which deeply attenuates measured signals (Khater & Ebaid, 2021), and, especially, the sample size, which controls the signal-noise ratio. Regardless of the background collection between each assay, samples' air drying, and lead foil shielding, unmanageable errors may have contributed to the absence of clustering or trending in radiometric data, primarily on the questioned/validation samples, mainly due to small sample sizes and low gamma-ray signal.

Even though sampling was carried out in the most undisturbed sites, many unknown factors could have affected the representativeness of single samples, such as former earthworks and debris disposal in illegal landfills, increasing uncertainty. As addressed in previous studies (Lark & Rawlins, 2008), the database and forensic specimens are commonly collected under distinct supports, where the latter may go through differentiation and mixing processes during walking or driving by a suspect. This

problem, therefore, can seriously influence provenancing, at risk of jeopardizing the operation. Although, the forensic analyst must be aware to individually collect soils with different colors or textures and retrieve a representative amount of samples - not just in terms of sample weight, but also spatially. In this study, the undersampling of the PSacq ($n = 2$), QPg ($n = 4$), PSacd ($n = 5$), and Qha ($n = 10$) considerably compromised the goal to define its signatures and, therefore, resulted in biased regression models.

Enhanced weathering may have been one of the major responsible for the reported mispredictions. The harsh conditions of the humid subtropical environment in which the ROI developed speed up the leaching and acid hydrolysis rate of silicate minerals, leaving mostly 1:1 clay minerals (i.e. kaolinite, as suggested by the climate features), quartz, Fe-Al oxides/hydroxides, and heavy metals in topsoil, evidenced by the limited mobility and strong depth correlation of the MS, LE, Fe, Ni, Cu, Mn, and lightness variables. Therefore, pedogenesis removes distinguishing features of the bedrock and its signature. Semi-quantitative non-destructive analysis, thus, may lack the power to discriminate these similar samples, even when from different geological units.

Overall, the analytical methods that performed as best predictors were magnetic susceptibility analysis and, to a lesser extent, pXRF and colorimetry, corroborating similar studies (de Caritat *et al.*, 2021; Ma *et al.*, 2021; Menchaca *et al.*, 2018; Tighe *et al.*, 2018). Gamma-ray spectrometry and ATR-FTIR, however, failed to provide relevant information that could be used as a tool for soil provenancing. This issue, although, may be related to the nearly uniform IR spectrum of the silicate functional groups and the higher mobility of ^{232}Th and ^{40}K in the database samples, which may also be climate-correlated, since the FTIR method had higher accuracy when applied to sourcing temperate soils (de Caritat *et al.*, 2021).

Besides, pyrolysis at 650°C may have modified physico-chemical properties as well. When dealing with organic matter-rich soils, one may face the short-blanket dilemma: as it is known that the presence of OM can affect pXRF (Bergslien, 2019) and color analysis results (Wills *et al.*, 2007), its removal using aqueous reactants are often inefficient and can modify and dissolve minerals, especially phyllosilicates (Mikutta *et al.*, 2005). On the other hand, as pyrolysis can properly eliminate organic content, it also induces phase transformation, dehydroxylation and structural changes in many silicates

and oxides (Török & Hajpál, 2005) present in soil, interfering in XRD and FTIR spectra. Therefore, the operator must be aware of these pitfalls prior to establishing the pre-treatment protocols.

Even though, non-destructive methods have many advantages, such as cost-effectiveness, reliability, rapid analysis, minimum sample preparation, and can easily be transported either to the crime scene, court, or between laboratories. The operator, however, must be cautious about its limitations and, if possible, establish quality control protocols. Destructive analysis, on the other hand, provides much more precise data and had been successfully used in many forensic provenancing studies (Aitkenhead *et al.*, 2014; Hoogewerff *et al.*, 2019; Saye & Pye, 2004), allowing to deeply characterize the soil samples, such as trace element composition and stable isotope ratios, which may be useful even with extremely weathered soils. For that matter, sequential extractions and analyses of low crystallinity oxides and aluminosilicates might also be appropriate, keeping in mind the impossibility of sample recovery (Testoni *et al.*, 2020; Testoni *et al.*, 2019).

5. CONCLUSIONS

The present study was designed to investigate the limitations and possibilities regarding forensic provenancing of subtropical soils in southern Brazil. Results from 232 reference (< 5 cm) and 14 validation samples provided compelling evidence that even moderately weathered and organic-rich materials can be traced using non-destructive analysis (magnetic susceptibility, gamma-ray spectrometry, colorimetry, pXRF, and ATR-FTIR), narrowing down as much as 97.5% of the original region of interest after applying the Search Range (SR) method, and 63.4% with the Euclidean distance (ED) algorithm. Findings also suggest that parent rock can influence some geophysical and geochemical attributes of the upper layer in warm and humid climates. Moreover, a significant depth correlation (> ~70%) was observed associated with MS, light elements group (LE), Fe, Cu, Mn, Ni, and lightness index, raising questions about the potential efficacy of former soil surveys for forensic applications.

One of the major limitations lies in the inherent inaccuracy of the employed analytical instruments and the uncertainty of the produced geostatistical surfaces, which

were based on empirical Bayesian kriging (EBK) regression prediction. It is an open question, however, to what degree more sophisticated non-destructive analysis can aid in spatial modeling and enhance predictability. Continued efforts are needed to deeply understand how far we can go into forensic sourcing with less and less soil sample size, especially in extreme environmental conditions.

ACKNOWLEDGMENTS

This study was funded by the Brazilian Coordination for the Improvement of Higher Education Personnel (CAPES). We thank the Geology Graduate Program of the Federal University of Paraná for providing round-the-clock support; the Lamir Institute (iLamir), the Laboratory for Sedimentological Studies and Sedimentary Petrology (LabESed), and the Laboratory for Research in Applied Geophysics (LPGA) for supplying the infrastructure and technical guidance; the Brazilian Federal Police (BFP), for forensic counseling and access to instruments; and, in particular, Dr. Fábio A. S. Salvador, Dr. Vander de F. Melo and Dr. Samara A. Testoni for unwavering support and partnership.

4.2 Resultados Complementares

Além do artigo principal contendo os dados referentes aos métodos de predição com intervalos de confiança e distância Euclidiana, foram avaliados também o potencial de diversos algoritmos de aprendizagem de máquina supervisionada.

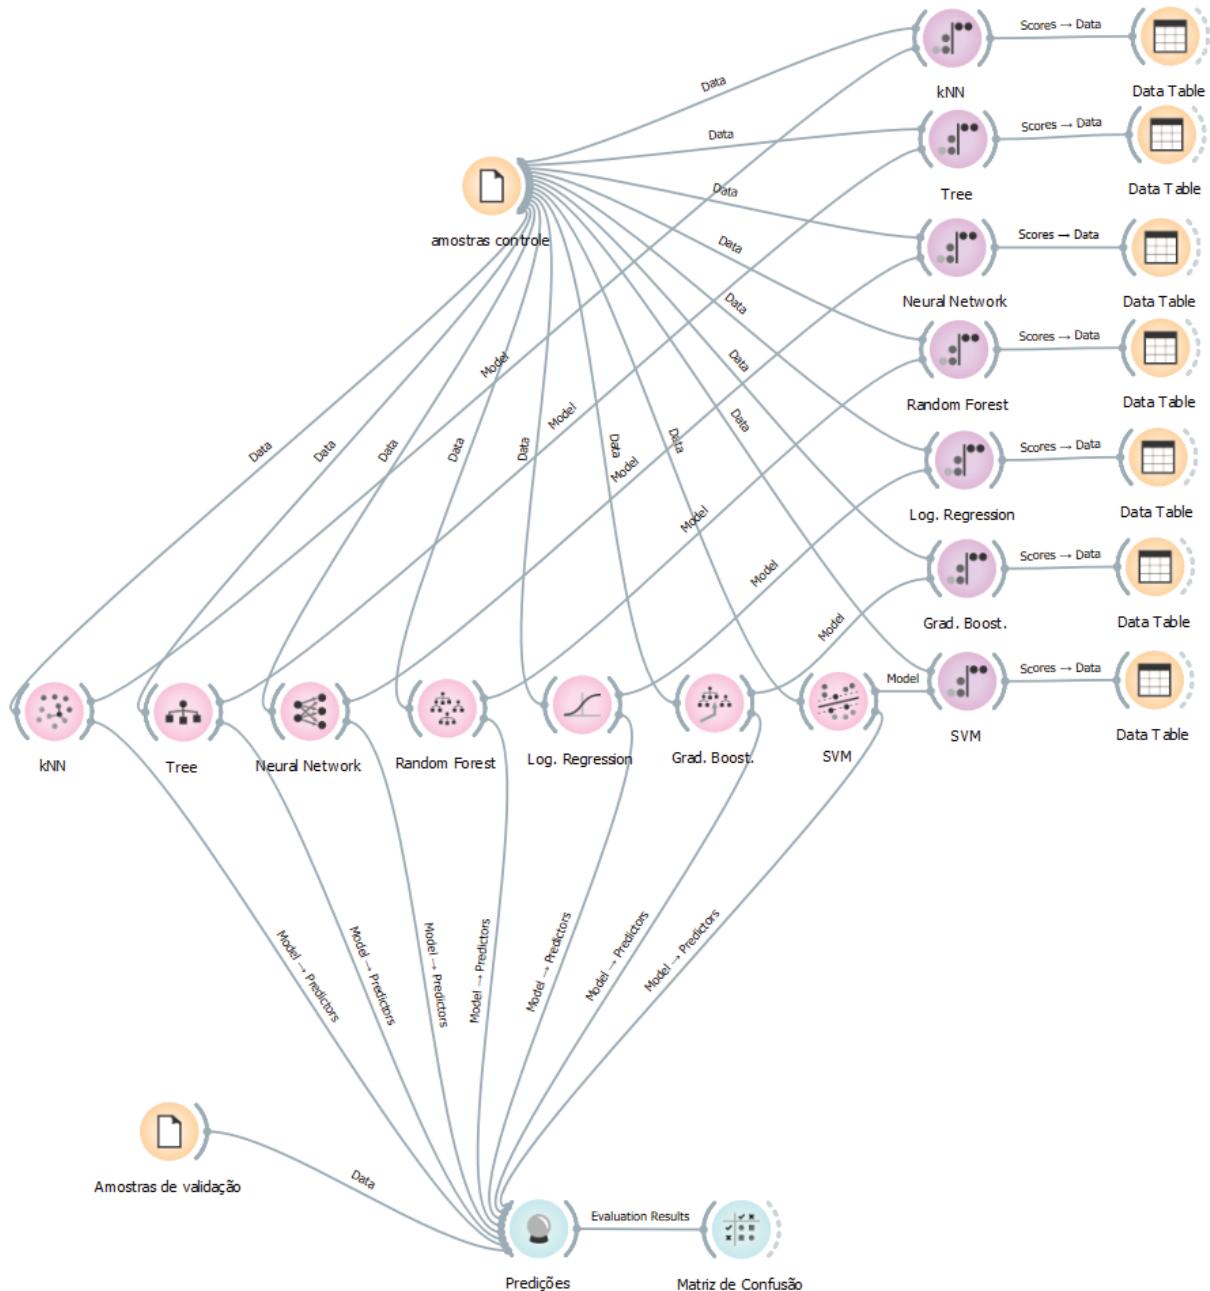


Figura 10 – Estrutura dos modelos de aprendizagem supervisionada, elaborados no *software Orange 3.3*.

A Figura 9 ilustra a estrutura e arranjo dos algoritmos aplicados no *software* Orange 3.3. A partir das amostras controle, as 7 funções de aprendizagem supervisionada foram aplicadas concomitantemente. Com base nas amostras de validação, modelos de predição foram gerados e avaliados na matriz de confusão. Além disso, para cada algoritmo, observou-se quais variáveis são mais impactantes na definição das assinaturas de cada unidade litoestratigráfica e pedológica (Tabela 4), ou seja, quais parâmetros melhor explicam o modelo preditivo das classes.

Tabela 4 - Variáveis que mais explicam os modelos preditivos, para cada unidade geológica e pedológica.

<i>Algoritmo</i>	Plagn	PSacm	PSacd	PSacq	QPg	QPg2	Qha	JKd
<i>k</i> -NN †	SM ^β	Mn	SI	Ti	SM	C=O	C=O	SM
<i>Árvore de decisões</i>	Si-O	Zn	Pb	Si-O-Si	Mn	Ti	Zn	Fe
<i>Redes neurais</i>	Si-O-Si	Si-O-Si	Red.	Sat.	K	Nb	C=O	Cu
<i>Floresta aleatória</i>	Si-O	LE	LE	Fe	Ti	Ti	LE	LE
<i>Regressão logística</i>	Si-O-Si	Si-O-Si	SM	Ti	SM	Ti	C=O	SM
<i>Gradient Boosting</i>	Si-O-Si	LE	Pb	LE	Si-O-Si	Ti	Zn	Cu
<i>SVM</i> ‡	²³⁸ U	Zr	Red.	Sat.	Zn	²³⁸ U	C=O	SM

<i>Algoritmo</i>	Argisolo	Cambissolo	Latossolo	Nitossolo	Organossolo
<i>k</i> -NN	SM	SM	SM	Mn	C=O
<i>Árvore de decisões</i>	Zn	Zr	Zn	Ti	Zr
<i>Redes neurais</i>	²³² Th	Si-O-Al	Si-O-Al	K	Zr
<i>Floresta aleatória</i>	Si-O	Si-O-Si	Zr	Si-O-Fe	Si-O-Fe
<i>Regressão logística</i>	B	Si-O-Al	Si-O-Al	Ti	C=O
<i>Gradient Boosting</i>	Zn	Si-O-Si	Si-O-Si	Ti	Ni
<i>SVM</i>	Th	Zr	Zr	K	Zr

† K-vizinhos mais próximos; ‡ máquina de vetores de suporte; β susceptibilidade magnética.

Para a unidade vulcânica JKd, as variáveis que melhor se destacaram foram a susceptibilidade magnética e outras propriedades correlatas, como o teor de Fe, Cu e

elementos leves (LE). Já para os sedimentos aluvionares recentes (Qha), houve um predomínio do grupo funcional carbonila (C=O). Para a unidade Quaternária depositada em cavidades kárticas (QPg2), o teor de Ti se sobressaiu em 4 dos 7 algoritmos de ML. Os modelos da unidade gnáissica-migmatítica (Piagn) foram melhor explicados pelos grupos funcionais silicáticos (Si-O e Si-O-Si), além da susceptibilidade magnética (SM) e radioatividade de ^{238}U . Para as demais unidades, não foram observados padrões claros de variáveis significativas. Para as unidades pedológicas, também não foi constatada uma tendência contínua de variáveis para a mesma classe de solo.

Tabela 5 - Performance dos algoritmos de aprendizagem supervisionada, em termos de acurácia e precisão

<i>Algoritmo</i>	<i>Unidades geológicas</i>		<i>Unidades pedológicas</i>	
	Acurácia (%)	Precisão (%)	Acurácia (%)	Precisão (%)
<i>Redes neurais</i>	71,4	61,3	57,1	51,9
<i>Máquina de vetores de suporte</i>	64,3	59,5	71,4	51,0
<i>Árvore de decisão</i>	57,1	55,9	71,4	65,6
<i>Regressão logística</i>	57,1	55,9	57,1	47,6
<i>K-vizinhos mais próximos</i>	57,1	53,6	71,4	54,9
<i>Gradient Boosting</i>	50,0	51,2	71,4	54,9
<i>Floresta aleatória</i>	42,9	49,2	71,4	65,6

Em relação à performance (Tabela 5), o algoritmo que obteve melhores resultados para identificar a unidade geológica de origem foi redes neurais artificiais, com acurácia e precisão de 71,4 e 61,3%, respectivamente. Nas mesmas condições, floresta aleatória apresentou as piores pontuações, com 42,9 e 49,2%. Em termos de predição de classe pedológica, tanto o algoritmo árvore de decisão quanto floresta aleatória apresentaram resultados relevantes, equivalente a 71,4 e 65,6% de acurácia e precisão, nesta ordem.

São diversos os parâmetros ajustáveis para cada função de aprendizagem supervisionada, como a quantidade de vizinhos no kNN, o número de instâncias e limites

de subdivisões em árvore de decisão, quantidade de neurônios e valor máximo de iterações em redes neurais artificiais (RNA), número máximo de árvores em floresta aleatória, entre outros. Para este estudo, foram adotadas as configurações padrões contidas no *software*. Logo, não é possível afirmar que as avaliações aqui apontadas são estáticas e invariáveis, uma vez que cada ajuste na função pode modificar consideravelmente a performance final de cada algoritmo. Além disso, certas classes geológicas ou pedológicas apresentaram baixa população amostral, o que pode contribuir para a influência de viés de frequência nos resultados, como no caso das unidades PSacq e PSacd, com poucas amostras de treinamento dos modelos.

Raros são os esforços na literatura que buscam desenvolver e aplicar ferramentas de aprendizagem de máquina, supervisionada ou não, em estudos de proveniência de solo para fins forenses. Para situações que envolvam extensas bases de dados (*big data*), como levantamentos geoquímicos regionais em escala de detalhe, *machine learning* tem a capacidade de aplicar cálculos matemáticos complexos e indicar nuances estatísticas relevantes não percebidas pelos métodos tradicionais de análise de dados. Recomenda-se assim, que, quando aplicável, cientistas forenses ou peritos criminais não confiem cegamente em resultados produzidos por algoritmos de inteligência artificial, mas que sejam consultados, avaliados e confirmados caso a caso.

5 CONSIDERAÇÕES FINAIS

A partir da construção e avaliação de um banco de dados georreferenciado de propriedades químicas e físicas de solo superficial (< 5 cm), em uma área de 100 km² entre os municípios de Almirante Tamandaré (PR) e Colombo (PR), foi possível estimar a origem geográfica de amostras-cegas de validação, com base em análises não-destrutivas de susceptibilidade magnética (SM), radiometria, cor, espectrometria de raios-X portátil (pXRF) e espectrometria de infravermelho com transformada de Fourier e reflectância total atenuada (ATR-FTIR). Utilizando-se o método de predição dos intervalos de confiança (IC), pôde-se reduzir a área de busca entre 67,7 e 97,5%, em 4 das 14 amostras de validação, a partir da definição das zonas com alta probabilidade de proveniência. Já com base no método da distância euclidiana (ED), a origem de 8 amostras foi corretamente estimada na classe mais preditiva, eliminando-se de 55 a 63,4% da área original. Em questão de desempenho dos métodos de aprendizagem de máquina, redes neurais foi o algoritmo que melhor se destacou, predizendo acuradamente a unidade litoestratigráfica de origem de 71% das amostras de validação.

Além disso, com base em amostras coletadas em horizonte B, observou-se uma correlação significante (> ~70%) com os níveis superficiais (< 5 cm), para os dados de susceptibilidade magnética (SM), grupo dos elementos leves (LE), brilho e os teores de Fe, Cu, Mn e Ni. Isso levanta a hipótese, portanto, sobre a possibilidade de utilização de dados de levantamentos geoquímicos regionais de solos para estimativa da distribuição espacial de certos atributos dos níveis pedológicos rasos de maior interesse forense.

Apesar das limitações inerentes aos métodos não-destrutivos, os quais contribuem para o aumento dos erros de predição nos modelo geoestatístico, este trabalho demonstrou que mesmo vestígios de solo ricos em matéria orgânica, pertencentes a ambientes subtropicais úmidos de intenso intemperismo químico, são passíveis de terem sua origem geográfica determinada. Todavia, estudos mais detalhados são necessários para definir novos horizontes neste tipo de abordagem.

6 REFERÊNCIAS

- Aardahl, K. (2003). *Evidential Value of Glitter Particle Trace Evidence*. National University, San Diego. <https://books.google.com.br/books?id=cSAFtwAACAAJ>
- Aberle, M. G. (2017). *The Potential of Soil Evidence in Provenance Determination for Forensic Intelligence Applications*.
- Aitkenhead, M. J., Coull, M. C., & Dawson, L. A. (2014). Predicting Sample Source Location from Soil Analysis Using Neural Networks. *Environmental Forensics*, 15(3). <https://doi.org/10.1080/15275922.2014.930764>
- Aitkenhead, M. J., Coull, M., Towers, W., Hudson, G., & Black, H. I. J. (2013). Prediction of soil characteristics and colour using data from the National Soils Inventory of Scotland. *Geoderma*, 200–201, 99–107. <https://doi.org/10.1016/j.geoderma.2013.02.013>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Moraes Gonçalves, J. L., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Anon. (1856). Curious Use of the Microscope. *Scientific American*, 11(30), 240. <http://www.jstor.org/stable/24950846>
- Antoci, P. R., & Petraco, N. (1993). A Technique for Comparing Soil Colors in the Forensic Laboratory. *Journal of Forensic Sciences*, 38(2). <https://doi.org/10.1520/jfs13425j>
- ASTM D2487-00. (2000). Standard Practice for Classification of Soils for Engineering Purposes (Unified Soil Classification System) D2487-00. *Anual Book of ASTM. Committee D18.07 on Identification and Classification of Soils*, 04(June 2006).
- ASTM E3272 - 21 Standard Guide for Collection of Soils and Other Geological Evidence for Criminal Forensic Applications.* (n.d.). Retrieved August 22, 2021, from <https://www.astm.org/Standards/E3272.htm>
- Barone, P. M., & di Maggio, R. M. (2017). *Introduction to Forensic Geoscience*. https://doi.org/10.1007/978-3-319-58048-7_1

- Bergslien, E. (2019). Portable X-ray fluorescence (PXRF) spectrometry of earth materials: considerations for forensic analysis. *Geological Society, London, Special Publications*, SP492-2017–2346. <https://doi.org/10.1144/sp492-2017-346>
- Bergslien, E. T. (2013). X-ray diffraction and field portable X-ray fluorescence analysis and screening of soils: Project design. *Geological Society Special Publication*, 384(1). <https://doi.org/10.1144/SP384.14>
- Bittencourt, E. A., & Iwamura, E. S. M. (2019). Brazilian DNA database—Establishment, legislation and accreditation. *Forensic Science International: Genetics Supplement Series*, 7(1). <https://doi.org/10.1016/j.fsigss.2019.10.036>
- Bowen, A. M., & Caven, E. A. (2013). Forensic provenance investigations of soil and sediment samples. *Geological Society Special Publication*, 384(1), 9–25. <https://doi.org/10.1144/SP384.4>
- Briggs, I. C. (1974). Machine contouring using minimum curvature. *GEOPHYSICS*, 39(1), 39–48. <https://doi.org/https://doi.org/10.1190/1.1440410>
- British Standards Institution. (2002). BS EN ISO 14688-1:2002 Geotechnical Investigation and Testing - Identification and Classification of Soil - Part 1: Identification and Description. In *BSI Standards Publication*.
- Brown, A., Smith, A., & Elmhurst, O. (2002). The Combined Use of Pollen and Soil Analyses in a Search and Subsequent Murder Investigation. *Journal of Forensic Sciences*, 47(3). <https://doi.org/10.1520/jfs15302j>
- Bull, P. A., Parker, A., & Morgan, R. M. (2006). The forensic analysis of soils and sediment taken from the cast of a footprint. *Forensic Science International*, 162(1–3), 6–12. <https://doi.org/10.1016/j.forsciint.2006.06.075>
- Campos Neto, M. da C. (2000). Orogenic systems from Southwestern Gondwana : an approach to Brasiliano- Pan African cycle and orogenic collage in southeastern Brazil. In *Tectonic evolution of South America* (Issue June).
- Cengiz, S., Karaca, A. C., Çakir, I., Üner, H. B., & Sevindik, A. (2004). SEM-EDS analysis and discrimination of forensic soil. *Forensic Science International*, 141(1). <https://doi.org/10.1016/j.forsciint.2003.12.006>

- Chauhan, R., Kumar, R., Diwan, P. K., & Sharma, V. (2020). Thermogravimetric analysis and chemometric based methods for soil examination: Application to soil forensics. *Forensic Chemistry*, 17. <https://doi.org/10.1016/j.forc.2019.100191>
- Chauhan, R., Kumar, R., & Sharma, V. (2018). Soil forensics: A spectroscopic examination of trace evidence. *Microchemical Journal*, 139. <https://doi.org/10.1016/j.microc.2018.02.020>
- Cheshire, K., Morgan, R. M., & Holmes, J. (2017). The potential for geochemical discrimination of single- and mixed-source soil samples from close proximity urban parkland locations. *Australian Journal of Forensic Sciences*, 49(2), 161–174. <https://doi.org/10.1080/00450618.2016.1144789>
- Clark, D. A. (1997). Magnetic petrophysics and magnetic petrology: aids to geological interpretation of magnetic surveys. *AGSO Journal of Australian Geology and Geophysics*, 17(2).
- Cocking, J. H., Turley, R., Fofanov, V. Y., Samuels-Crow, K., Hungate, B., Mau, R. L., Keim, P. S., Caporaso, J. G., & Hepp, C. (2020). Forensic analysis of soil microbiomes: Linking evidence to a geographic location. *BioRxiv*. <https://doi.org/10.1101/2020.07.10.198044>
- Coimbra, A. M., & Coutinho, J. M. v. (1976). Curioso exemplo de aplicação de análise sedimentológica. *XIX Congresso Brasileiro de Geologia*, 53.
- Concheri, G., Bertoldi, D., Polone, E., Otto, S., Larcher, R., & Squartini, A. (2011). Chemical elemental distribution and soil DNA fingerprints provide the critical evidence in murder case investigation. *PLoS ONE*, 6(6). <https://doi.org/10.1371/journal.pone.0020222>
- Corrêa, R. S., Melo, V. F., Abreu, G. G. F., Sousa, M. H., Chaker, J. A., & Gomes, J. A. (2018). Soil forensics: How far can soil clay analysis distinguish between soil vestiges? *Science and Justice*, 58(2). <https://doi.org/10.1016/j.scijus.2017.09.003>
- Cox, R. J., Peterson Bs, H. L., Bs, J. Y., Cusik Bs, C., & Espinoza, E. O. (2000). The forensic analysis of soil organic by FTIR. In *Forensic Science International* (Vol. 108). www.elsevier.com/locate/forsciint

- Croft, D. J., & Pye, K. (2004). Colour theory and evaluation of an instrumental method of measurement using geological samples for forensic applications. *Geological Society Special Publication*, 232. <https://doi.org/10.1144/GSL.SP.2004.232.01.07>
- Da, G. A., & Sadowski, G. R. (1999). Tectonics of the southern portion of the Ribeira Belt (Apiaí Domain). *Precambrian Research*, 98(1–2). [https://doi.org/10.1016/S0301-9268\(99\)00027-3](https://doi.org/10.1016/S0301-9268(99)00027-3)
- da Silva Junior, R. C., Minervino, A. C., Martinez, L. L., Russo, D., & Miranda, D. A. (2019). Geolocation of the Brazilian National DNA Database matches as a tool for improving public safety and the promotion of justice. *Forensic Science International: Genetics Supplement Series*, 7(1). <https://doi.org/10.1016/j.fsigss.2019.10.086>
- Dawson, L. A., & Hillier, S. (2010). Measurement of soil characteristics for forensic applications. *Surface and Interface Analysis*, 42(5), 363–377. <https://doi.org/10.1002/sia.3315>
- de Almeida, F. F. M., Amaral, G., Cordani, U. G., & Kawashita, K. (1973). The Precambrian Evolution of the South American Cratonic Margin South of the Amazon River. In *The South Atlantic*. https://doi.org/10.1007/978-1-4684-3030-1_11
- de Almeida, F. F. M., Hasui, Y., de Brito Neves, B. B., & Fuck, R. A. (1981). Brazilian structural provinces: An introduction. *Earth Science Reviews*, 17(1–2). [https://doi.org/10.1016/0012-8252\(81\)90003-9](https://doi.org/10.1016/0012-8252(81)90003-9)
- de Brito Neves, B. B., Campos Neto, M. D. C., & Fuck, R. A. (1999). From Rodinia to Western Gondwana: An approach to the Brasiliano-Pan African cycle and orogenic collage. In *Episodes* (Vol. 22, Issue 3). <https://doi.org/10.18814/epiiugs/1999/v22i3/002>
- de Bruin, M., & Schmitz, P. M. U. (2021). The application of forensic geomorphology in rhinoceros poaching investigations in Africa. *South African Geographical Journal*, 103(1). <https://doi.org/10.1080/03736245.2020.1835700>
- de Caritat, P., Simpson, T., & Woods, B. (2019). Predictive Soil Provenancing (PSP): An Innovative Forensic Soil Provenance Analysis Tool. *Journal of Forensic Sciences*, 64(5), 1359–1369. <https://doi.org/10.1111/1556-4029.14060>

- de Caritat, P., Woods, B., Simpson, T., Nichols, C., Hoogenboom, L., Ilheo, A., Aberle, M. G., & Hoogewerff, J. (2021). Forensic soil provenancing in an urban/suburban setting: A sequential multivariate approach. *Journal of Forensic Sciences*. <https://doi.org/10.1111/1556-4029.14727>
- de Lima, F. M., Fernandes, L. A., de Melo, M. S., Góes, A. M., & Machado, D. A. M. (2013). Faciologia e contexto deposicional da Formação Guabirotuba, Bacia de Curitiba (PR). *Brazilian Journal of Geology*, 43(1). <https://doi.org/10.5327/Z2317-48892013000100014>
- de Oliveira, J. C., de Paula Souza, L. C., de Freitas Melo, V., & da Rocha, H. O. (2011). Spatial variability of mineralogical properties in soil of the guabirotuba formation of Curitiba (PR). *Revista Brasileira de Ciencia Do Solo*, 35(5). <https://doi.org/10.1590/s0100-06832011000500002>
- de Oliveira, P. E., & Suguio, K. (2005). Estudos quaternários e sua aplicação forense: caso estudo de containers furtados no estado de São Paulo. *XI Congresso Da Associação Brasileira de Estudos Quaternários*, 1–5.
- di Maggio, R. M., Donnelly, L. J., al Naimi, K. S., Barone, P. M., da Silva Salvador, F. A., Dawson, L., Dixon, R., Fitzpatrick, R., Gradusova, O., Nesterina, E., Peleneva, M., Ushacova, O., Gallego, C. M. M., Pirrie, D., Ruffell, A., McKinley, J., Sagripanti, G., Villalba, D., Schneck, B., ... Forbes, S. (2017). Global developments in forensic geology. In *Episodes* (Vol. 40, Issue 2). <https://doi.org/10.18814/epiiugs/2017/v40i2/017014>
- Dong, C. E., Webb, J. B., Bottrell, M. C., Saginor, I., Lee, B. D., & Stern, L. A. (2020). Strengths, Limitations, and Recommendations for Instrumental Color Measurement in Forensic Soil Characterization. *Journal of Forensic Sciences*, 65(2). <https://doi.org/10.1111/1556-4029.14193>
- Donnelly, L. (2011). The Renaissance in Forensic Geology. *Teaching Earth Sciences*, 36(1).
- Donnelly, L. (2020). A standard operating procedure (SOP), for soil sampling, for the detection of volatile organic compounds and leachate associated with human

- decomposition from a shallow, unmarked, homicide grave. *Geological Society, London, Special Publications*. <https://doi.org/10.1144/sp492-2020-58>
- Donnelly, L. J., Cassella, J., Pirrie, D., Dawson, L., Blom, G., Davidson, A., Arnold, P., Harrison, M., & Hope, C. (2019). Analysis of soil following a police-led open area search and the recovery of a cold-case homicide grave. *Geological Society, London, Special Publications*, SP492-2017–2337. <https://doi.org/10.1144/sp492-2017-337>
- Dudley, R. J. (1975). The Use of Colour in the Discrimination Between Soils. *Journal of the Forensic Science Society*, 15(3), 209–218. [https://doi.org/10.1016/S0015-7368\(75\)70986-6](https://doi.org/10.1016/S0015-7368(75)70986-6)
- Dudley, R. J., & Smalldon, K. W. (1978). The evaluation of methods for soil analysis under simulated scenes of crime conditions. *Forensic Science International*, 12(1). [https://doi.org/10.1016/0379-0738\(78\)90033-6](https://doi.org/10.1016/0379-0738(78)90033-6)
- Embrapa. (2013). Sistema brasileiro de classificação de solos. In *Embrapa Solos*.
- ENFSI, E. N. of F. S. I. (2019). *Best Practice Manual for the Forensic Comparison of Soil Traces*. 1(ENFSI-BPM-APS-02), 1–24. www.enfsi.eu
- Eppich, G. R. (2020). Nuclear forensics: How science helps stop the trafficking of nuclear materials. *Bulletin of the Atomic Scientists*, 76(5). <https://doi.org/10.1080/00963402.2020.1806587>
- Fiori, A. P. (1992). Tectonica e estratigrafia do Grupo Acungui - PR. *Boletim IG - Universidade de Sao Paulo, Instituto de Geociencias*, 23. <https://doi.org/10.11606/issn.2316-8986.v23i0p55-74>
- Fiori, A. P., & Gaspar, L. A. (1993). Consideracoes sobre a estratigrafia do Grupo Acungui (Proterozoico Superior), Parana, sul do Brasil. *Boletim IG - Universidade de Sao Paulo, Instituto de Geociencias: Serie Cientifica*, 24. <https://doi.org/10.11606/issn.2316-8986.v24i0p1-19>
- Fitzpatrick, R., Raven, M., & Self, P. (2017). The role of pedology and mineralogy in providing evidence for 5 crime investigations involving a wide range of earth materials. *Episodes*, 40(2). <https://doi.org/10.18814/epiugs/2017/v40i2/017017>

- Fitzpatrick, R. W. (2013). Soil: Forensic Analysis. In *Wiley Encyclopedia of Forensic Science* (pp. 1–14). American Cancer Society. <https://doi.org/https://doi.org/10.1002/9780470061589.fsa096.pub2>
- Fitzpatrick, R. W., & Donnelly, L. J. (2021). An introduction to forensic soil science and forensic geology: a synthesis. *Geological Society, London, Special Publications*. <https://doi.org/10.1144/sp492-2021-81>
- Fitzpatrick, R. W., & Raven, M. (2005). Soil mineralogy and other properties in forensic investigations. *Acta Crystallographica Section A Foundations of Crystallography*, 61(a1), c14–c14. <https://doi.org/10.1107/s0108767305099381>
- Fitzpatrick, R. W., & Raven, M. D. (2012). How Pedology and Mineralogy Helped Solve a Double Murder Case: Using Forensics to Inspire Future Generations of Soil Scientists. *Soil Horizons*, 53(5), 14. <https://doi.org/10.2136/sh12-05-0016>
- Fitzpatrick, R. W., & Raven, M. D. (2016). *Centre for Australian Forensic Soil Science Guidelines for Conducting Criminal and Environmental Soil Forensic Investigations: Version 10.1*. <https://doi.org/10.1>
- Fitzpatrick, R. W., & Raven, M. D. (2019). *The forensic comparison of trace amounts of soil on a pyjama top with hypersulphidic subaqueous soil from a river as evidence in a homicide cold case*. <https://doi.org/10.6084/m9.fig>
- Fitzpatrick, R. W., Raven, M. D., & Forrester, S. T. (2009). A Systematic Approach to Soil Forensics: Criminal Case Studies Involving Transference from Crime Scene to Forensic Evidence. In K. Ritz, L. Dawson, & D. Miller (Eds.), *Criminal and Environmental Soil Forensics* (pp. 105–127). Springer Netherlands. https://doi.org/10.1007/978-1-4020-9204-6_8
- García-Delgado, R. A., García-Herruzo, F., Rodríguez-Maroto, J. M., & Vereda, C. (1996). Influence of soil carbonates in lead fixation. *Journal of Environmental Science and Health - Part A Toxic/Hazardous Substances and Environmental Engineering*, 31(9). <https://doi.org/10.1080/10934529609376479>
- Gribov, A., & Krivoruchko, K. (2020). Empirical Bayesian kriging implementation and usage. *Science of the Total Environment*, 722. <https://doi.org/10.1016/j.scitotenv.2020.137290>

- Gross, H. (1893). *Handbuch für Untersuchungsrichter, Polizeibeamte, Gendarmen u.s.w.* Leuschner & Lubensky.
- Guedes, A., Murray, R. C., Ribeiro, H., Sant’Ovaia, H., Valentim, B., Rodrigues, A., Leal, S., & Noronha, F. (2013). The potential application of magnetic susceptibility as a technique for soil forensic examinations. *Geological Society Special Publication*, 384(1). <https://doi.org/10.1144/SP384.7>
- Guedes, A., Ribeiro, H., Valentim, B., & Noronha, F. (2009). Quantitative colour analysis of beach and dune sediments for forensic applications: A Portuguese example. *Forensic Science International*, 190(1–3), 42–51. <https://doi.org/10.1016/j.forsciint.2009.05.010>
- Guedes, A., Ribeiro, H., Valentim, B., Rodrigues, A., Sant’Ovaia, H., Abreu, I., & Noronha, F. (2011). Characterization of soils from the Algarve region (Portugal): A multidisciplinary approach for forensic applications. *Science and Justice*, 51(2). <https://doi.org/10.1016/j.scijus.2010.10.006>
- Guimaraes, S. B., dos Reis Neto, J. M., & Siqueira, R. B. L. (2002). Caracterização dos estromatólitos da formação Capiru (Proterozoico) nas Regiões de Morro Azul e Morro grande leste do Paraná. *Boletim Paranaense de Geociências*, 51. <https://doi.org/10.5380/geo.v51i0.4172>
- Guo, H., Wang, P., Hu, C., Zhu, J., Yang, X., Quan, Y., Mei, H., & Li, J. (2019). A case study in forensic soil examination from China. *Geological Society, London, Special Publications*, SP492-2017–2307. <https://doi.org/10.1144/sp492-2017-307>
- Hassan, N. F. N., Sandran, D. D., Mohamad, M., Zakaria, Y., & Muslim, N. Z. M. (2019). Estimation of the age of bloodstains on soil matrices by ATR-FTIR spectroscopy and chemometrics. *International Journal of Innovative Technology and Exploring Engineering*, 9(1). <https://doi.org/10.35940/ijitee.A4454.119119>
- Heilbron, M., Valeriano, C. M., Tassinari, C. C. G., Almeida, J., Tupinambá, M., Siga, J., & Trouw, R. (2008). Correlation of neoproterozoic terranes between the Ribeira Belt, SE Brazil and its African counterpart: Comparative tectonic evolution and open questions. *Geological Society Special Publication*, 294. <https://doi.org/10.1144/SP294.12>

- Hoogewerff, J. A., Reimann, C., Ueckermann, H., Frei, R., Frei, K. M., van Aswegen, T., Stirling, C., Reid, M., Clayton, A., & Ladenberger, A. (2019). Bioavailable $^{87}\text{Sr}/^{86}\text{Sr}$ in European soils: A baseline for provenancing studies. *Science of The Total Environment*, 672, 1033–1044. <https://doi.org/10.1016/J.SCITOTENV.2019.03.387>
- Horrocks, M., & Walsh, K. A. J. (1999). Fine Resolution of Pollen Patterns in Limited Space: Differentiating a Crime Scene and Alibi Scene Seven Meters Apart. *Journal of Forensic Sciences*, 44(2). <https://doi.org/10.1520/jfs14477j>
- Hou, X., He, Y., & Jones, B. T. (2004). Recent advances in portable x-ray fluorescence spectrometry. *Applied Spectroscopy Reviews*, 39(1). <https://doi.org/10.1081/ASR-120028867>
- IBGE. (2016). Mapa de Solos do Brasil. *Instituto Brasileiro de Geografia e Estatística*.
- IPEA. (2018). Atlas da Violência 2018. In *IPEA - Instituto de pesquisa econômica aplicada* (Issue 1).
- Isphording, W. C. (n.d.). *The right way and the wrong way of presenting statistical and geological evidence in a court of law (a little knowledge is a dangerous thing!)*. <http://sp.lyellcollection.org/>
- Jackson, M., & Swanson-Hysell, N. L. (2012). Rock magnetism of remagnetized carbonate rocks: Another look. *Geological Society Special Publication*, 371(1). <https://doi.org/10.1144/SP371.3>
- Jarvis, K. E., Wilson, H. E., & James, S. L. (2004). Assessing element variability in small soil samples taken during forensic investigation. *Geological Society Special Publication*, 232. <https://doi.org/10.1144/GSL.SP.2004.232.01.16>
- Kammrath, B. W., Koutrakos, A., Castillo, J., Langley, C., & Huck-Jones, D. (2018). Morphologically-directed Raman spectroscopy for forensic soil analysis. *Forensic Science International*, 285, e25–e33. <https://doi.org/10.1016/j.forsciint.2017.12.034>
- Kasu, M., & Shires, K. (2015). The validation of forensic DNA extraction systems to utilize soil contaminated biological evidence. *Legal Medicine*, 17(4). <https://doi.org/10.1016/j.legalmed.2015.01.004>

- Keaney, A., Ruffell, A., & McKinley, J. (2009). Geological trace evidence: Forensic and legal perspectives. In *Criminal and Environmental Soil Forensics*. https://doi.org/10.1007/978-1-4020-9204-6_14
- Kearey, P., Brooks, M., & Hill, I. (2009). Geofísica de exploração. In *Oficina de Texto*.
- Khater, A. E. M., & Ebaid, Y. Y. (2021). Feasibility of Handheld BGO Gamma-Ray Spectrometer to Evaluate U and Th in Phosphate Ore Mining Area: A Case Study. *Journal of Radiation and Nuclear Applications*, 6(1). <https://doi.org/10.18576/jrna/060103>
- Kikkawa, H. S., Naganuma, K., Kumisaka, K., & Sugita, R. (2019). Semi-automated scanning electron microscopy energy dispersive X-ray spectrometry forensic analysis of soil samples. *Forensic Science International*, 305. <https://doi.org/10.1016/j.forsciint.2019.109947>
- Konopinski, D. I., Hudziak, S., Morgan, R. M., Bull, P. A., & Kenyon, A. J. (2012). Investigation of quartz grain surface textures by atomic force microscopy for forensic analysis. *Forensic Science International*, 223(1–3). <https://doi.org/10.1016/j.forsciint.2012.09.011>
- Kristo, M. J., Gaffney, A. M., Marks, N., Knight, K., Cassata, W. S., & Hutcheon, I. D. (2016). Nuclear Forensic Science: Analysis of Nuclear Material out of Regulatory Control. In *Annual Review of Earth and Planetary Sciences* (Vol. 44). <https://doi.org/10.1146/annurev-earth-060115-012309>
- Krivoruchko, K., & Gribov, A. (2019). Evaluation of empirical Bayesian kriging. *Spatial Statistics*, 32, 100368. <https://doi.org/10.1016/J.SPASTA.2019.100368>
- Krumbein, W. C. (1934). Size Frequency Distributions of Sediments. *SEPM Journal of Sedimentary Research*, Vol. 4. <https://doi.org/10.1306/d4268eb9-2b26-11d7-8648000102c1865d>
- Lark, R. M., & Rawlins, B. G. (2008). Can we predict the provenance of a soil sample for forensic purposes by reference to a spatial database? *European Journal of Soil Science*, 59(5), 1000–1006. <https://doi.org/10.1111/j.1365-2389.2008.01064.x>
- Lee, C. S., Sung, T. M., Kim, H. S., & Jeon, C. H. (2012). Classification of forensic soil evidences by application of THM-PyGC/MS and multivariate analysis. *Journal of*

- Analytical and Applied Pyrolysis*, 96, 33–42.
<https://doi.org/10.1016/j.jaap.2012.02.017>
- Li, M. F., Tang, X. P., Wu, W., & Liu, H. bin. (2013). General models for estimating daily global solar radiation for different solar radiation zones in mainland China. *Energy Conversion and Management*, 70. <https://doi.org/10.1016/j.enconman.2013.03.004>
- Liu, Y., Li, Y., Li, Q., Bao, J., Hao, D., Zhao, Z., Song, D., Wang, J., & Hu, Z. (2015). Micro- to Nanoscale Morphologies and Chemical Components of Soils Investigated by SEM-EDS for Forensic Science. *Journal of Chemistry*, 2015. <https://doi.org/10.1155/2015/734560>
- Locard, E. (1920). Traces et taches. In Ernest Flammarion (Ed.), *L'enquête criminelle et les méthodes scientifiques: Vol. IV* (pp. 139–170). Flammarion.
- Lorna Dawson, P. (2019). *Guidelines for Forensic Sampling of Scenes, Footwear and Vehicles for Soil and Vegetation*.
- Lu, S. G., Xue, Q. F., Zhu, L., & Yu, J. Y. (2008). Mineral magnetic properties of a weathering sequence of soils derived from basalt in Eastern China. *Catena*, 73(1). <https://doi.org/10.1016/j.catena.2007.08.004>
- Lützenkirchen, K., Wallenius, M., Varga, Z., Wiss, T., Knott, A., Nicholl, A., & Mayer, K. (2019). Nuclear forensics on uranium fuel pellets. *Radiochimica Acta*, 107(7). <https://doi.org/10.1515/ract-2018-3068>
- Ma, F., Du, C., Zhang, Y., Xu, X., & Zhou, J. (2021). LIBS and FTIR–ATR spectroscopy studies of mineral–organic associations in saline soil. *Land Degradation and Development*, 32(4). <https://doi.org/10.1002/ldr.3829>
- Ma, Y., Minasny, B., & McBratney, A. (2021). Identifying soil provenance based on portable X-ray fluorescence measurements using similarity and inverse-mapping approaches – A case in the Lower Hunter Valley, Australia. *Geoderma Regional*, 25. <https://doi.org/10.1016/j.geodrs.2021.e00368>
- Maher, B. A., & Taylor, R. M. (1988). Formation of ultrafine-grained magnetite in soils. *Nature*, 336(6197). <https://doi.org/10.1038/336368a0>
- Manrong, C., Lizhong, Y., Xiangfeng, N., & Bin, C. (2009). Application of environmental magnetism on crime detection in a highway traffic accident from Yangzhou to

- Guazhou, Jiangsu Province, China. *Forensic Science International*, 187(1–3). <https://doi.org/10.1016/j.forsciint.2009.02.012>
- Marqués-Mateu, Á., Moreno-Ramón, H., Balasch, S., & Ibáñez-Asensio, S. (2018). Quantifying the uncertainty of soil colour measurements with Munsell charts using a modified attribute agreement analysis. *Catena*, 171, 44–53. <https://doi.org/10.1016/j.catena.2018.06.027>
- McBride, M. B. (1994). Environmental chemistry of soils. *Environmental Chemistry of Soils*. <https://doi.org/10.2134/jeq1995.00472425002400010029x>
- McCulloch, G., Dawson, L. A., Brewer, M. J., & Morgan, R. M. (2017). The identification of markers for Geoforensic HPLC profiling at close proximity sites. *Forensic Science International*, 272. <https://doi.org/10.1016/j.forsciint.2017.01.009>
- McCulloch, G., Dawson, L. A., Ross, J. M., & Morgan, R. M. (2018). The discrimination of geoforensic trace material from close proximity locations by organic profiling using HPLC and plant wax marker analysis by GC. *Forensic Science International*, 288. <https://doi.org/10.1016/j.forsciint.2018.02.009>
- McCulloch, G., Morgan, R. M., & Bull, P. A. (2017). High Performance Liquid Chromatography as a valuable tool for geoforensic soil analysis. *Australian Journal of Forensic Sciences*, 49(4). <https://doi.org/10.1080/00450618.2016.1194474>
- Mckinley, J. (2013). How useful are databases in environmental and criminal forensics? *Geological Society Special Publication*, 384(1), 109–119. <https://doi.org/10.1144/SP384.9>
- McPhee, J. (1996, January 29). Death of an Agent. *The Gravel Page: The New Yorker*, 71(46), 60–69.
- Melo, V. F., Testoni, S. A., Dawson, L., de Lara, A. G., & da Silva Salvador, F. A. (2019). Can analysis of a small clod of soil help to solve a murder case? *Science and Justice*, 59(6), 667–677. <https://doi.org/10.1016/j.scijus.2019.06.008>
- Menchaca, P. R., Graham, R. C., & Younglove, T. (2018). Developing and Testing a Soil Property Database for Forensic Applications in Southern California. *Journal of Forensic Sciences*, 63(4), 1043–1052. <https://doi.org/10.1111/1556-4029.13723>

- Mikutta, R., Kleber, M., Kaiser, K., & Jahn, R. (2005). Review: Organic matter removal from soils using hydrogen peroxide, sodium hypochlorite, and disodium peroxodisulfate. *Soil Science Society of America Journal*, 69(1). <https://doi.org/10.2136/sssaj2005.0120>
- Milani, E. J., & de Wit, M. J. (2008). Correlations between the classic Paraná and Cape-Karoo sequences of South America and southern Africa and their basin infills flanking the Gondwanides: Du Toit revisited. *Geological Society Special Publication*, 294. <https://doi.org/10.1144/SP294.17>
- Minyuk, P. S., Subbotnikova, T. v., & Plyashkevich, A. A. (2011). Measurements of thermal magnetic susceptibility of hematite and goethite. *Izvestiya, Physics of the Solid Earth*, 47(9). <https://doi.org/10.1134/S1069351311080052>
- Morgan, R. M., & Bull, P. A. (2006). Data interpretation in forensic sediment and soil geochemistry. *Environmental Forensics*, 7(4), 325–334. <https://doi.org/10.1080/15275920600996248>
- Morgan, R. M., & Bull, P. A. (2007). The use of grain size distribution analysis of sediments and soils in forensic enquiry. *Science and Justice*, 47(3). <https://doi.org/10.1016/j.scijus.2007.02.001>
- Morgan, R. M., Cohen, J., McGookin, I., Murly-Gotto, J., O'Connor, R., Muress, S., Freudiger-Bonzon, J., & Bull, P. A. (2009). The relevance of the evolution of experimental studies for the interpretation and evaluation of some trace physical evidence. *Science and Justice*, 49(4), 277–285. <https://doi.org/10.1016/j.scijus.2009.02.004>
- Morgan, R. M., Scott, K. R., Ainley, J., & Bull, P. A. (2019). Journey history reconstruction from the soils and sediments on footwear: An empirical approach. *Science and Justice*, 59(3). <https://doi.org/10.1016/j.scijus.2018.11.002>
- Munsell Colour Company, & Munsell Colour Company. (1975). Munsell Soil Colour Charts. In *Geoderma* (Vol. 48, Issue 199, p. 199).
- Murray, K. R., Fitzpatrick, R. W., Bottrill, R. S., Berry, R., & Kobus, H. (2016). Soil transference patterns on bras: Image processing and laboratory dragging

- experiments. *Forensic Science International*, 258. <https://doi.org/10.1016/j.forsciint.2015.10.009>
- Murray, R. C. (2004a). *Evidence from the earth: forensic geology and criminal investigation*. Mountain Press Publishing Company.
- Murray, R. C. (2004b). Forensic geology: Yesterday, today and tomorrow. *Geological Society Special Publication*, 232. <https://doi.org/10.1144/GSL.SP.2004.232.01.02>
- Nakai, I., Furuya, S., Bong, W., Abe, Y., Osaka, K., Matsumoto, T., Itou, M., Ohta, A., & Ninomiya, T. (2014). Quantitative analysis of heavy elements and semi-quantitative evaluation of heavy mineral compositions of sediments in Japan for construction of a forensic soil database using synchrotron radiation X-ray analyses. *X-Ray Spectrometry*, 43(1), 38–48. <https://doi.org/10.1002/xrs.2496>
- NCFS, N. C. on F. S. (2014). *Pretrial discovery in Forensic Evidence cases*.
- Palenik, S. (2007). Heavy Minerals in Use. In *Developments in Sedimentology* (Vol. 58, Issue null).
- Pedersen, L. L., Smets, B. F., & Dechesne, A. (2015). Measuring biogeochemical heterogeneity at the micro scale in soils and sediments. In *Soil Biology and Biochemistry* (Vol. 90). <https://doi.org/10.1016/j.soilbio.2015.08.003>
- Petraco, N., Kubic, T. A., & Petraco, N. D. K. (2008). Case studies in forensic soil examinations. *Forensic Science International*, 178(2–3). <https://doi.org/10.1016/j.forsciint.2008.03.008>
- Pilchin, A. (2011). Magnetite: The story of the mineral's formation and stability. In *Magnetite: Structure, Properties and Applications*.
- Pirrie, D. (2018). Testing the efficiency of soil recovery from clothing for analysis by SEM-EDS. *Forensic Science International*, 289, 83–91. <https://doi.org/10.1016/j.forsciint.2018.05.026>
- Pirrie, D., Dawson, L., & Graham, G. (2017). Predictive geolocation: Forensic soil analysis for provenance determination. *Episodes*, 40(2), 141–147. <https://doi.org/10.18814/epiiugs/2017/v40i2/017016>

- Pirrie, D., Ruffell, A., & Dawson, L. A. (2013). Environmental and criminal geoforensics: An introduction. *Geological Society Special Publication*, 384(1), 1–7. <https://doi.org/10.1144/SP384.20>
- Prandel, L. V., Melo, V. F., Testoni, S. A., Brinatti, A. M., Saab, S. D. C., & Dawson, L. A. (2020). Spectroscopic techniques applied to discriminate soils for forensic purposes. *Soil Research*, 58(2). <https://doi.org/10.1071/SR19066>
- Pringle, J. K., Giubertoni, M., Cassidy, N. J., Wisniewski, K. D., Hansen, J. D., Linford, N. T., & Daniels, R. M. (2015). The use of magnetic susceptibility as a forensic search tool. *Forensic Science International*, 246. <https://doi.org/10.1016/j.forsciint.2014.10.046>
- Procter, F. A., Swindles, G. T., & Barlow, N. L. M. (2019). Examining the transfer of soils to clothing materials: Implications for forensic investigations. *Forensic Science International*, 305. <https://doi.org/10.1016/j.forsciint.2019.110030>
- Pye, K. (2007). *Geological and Soil Evidence: Forensic Applications* (1st ed.). CRC Press.
- Pye, K., Blott, S. J., & Wray, D. S. (2006). Elemental analysis of soil samples for forensic purposes by inductively coupled plasma spectrometry - precision considerations. *Forensic Science International*, 160(2–3), 178–192. <https://doi.org/10.1016/j.forsciint.2005.09.012>
- Pye, K., & Croft, D. (2007). Forensic analysis of soil and sediment traces by scanning electron microscopy and energy-dispersive X-ray analysis: An experimental investigation. *Forensic Science International*, 165(1). <https://doi.org/10.1016/j.forsciint.2006.03.001>
- Pyrcz, M. J., & Deutsch, C. (2007). *Declustering and debiasing*. <https://www.researchgate.net/publication/228427948>
- Ranjard, L., Nazaret, S., Gourbière, F., Thioulouse, J., Linet, P., & Richaume, A. (2000). A soil microscale study to reveal the heterogeneity of Hg(II) impact on indigenous bacteria by quantification of adapted phenotypes and analysis of community DNA fingerprints. *FEMS Microbiology Ecology*, 31(2). [https://doi.org/10.1016/S0168-6496\(99\)00089-6](https://doi.org/10.1016/S0168-6496(99)00089-6)

- Rawlins, B. G., & Cave, M. (2004). Investigating multi-element soil geochemical signatures and their potential for use in forensic studies. *Geological Society Special Publication*, 232. <https://doi.org/10.1144/GSL.SP.2004.232.01.18>
- Rawlins, B. G., Kemp, S. J., Hodgkinson, E. H., Riding, J. B., Vane, C. H., Poulton, C., & Freeborough, K. (2006). Potential and pitfalls in establishing the provenance of earth-related samples in forensic investigations. In *Journal of Forensic Sciences* (Vol. 51, Issue 4). <https://doi.org/10.1111/j.1556-4029.2006.00152.x>
- Rawlins, B. G., Webster, R., & Lister, T. R. (2003). The influence of parent material on topsoil geochemistry in eastern England. *Earth Surface Processes and Landforms*, 28(13). <https://doi.org/10.1002/esp.507>
- Reading, D. G., Croudace, I. W., Warwick, P. E., & Britton, R. (2015). A rapid dissolution procedure to aid initial nuclear forensics investigations of chemically refractory compounds and particles prior to gamma spectrometry. *Analytica Chimica Acta*, 900. <https://doi.org/10.1016/j.aca.2015.07.047>
- Reidy, L., Bu, K., Godfrey, M., & Cizdziel, J. v. (2013). Elemental fingerprinting of soils using ICP-MS and multivariate statistics: A study for and by forensic chemistry majors. *Forensic Science International*, 233(1–3), 37–44. <https://doi.org/10.1016/j.forsciint.2013.08.019>
- Rendle, D. F. (2004). Database use in forensic analysis. *Crystallography Reviews*, 10(1), 23–28. <https://doi.org/10.1080/08893110410001664927>
- Robertson, A. H. J., Main, A. M., Robinson, L. J., & Dawson, L. A. (2015). In situ FTIR analysis of soils for forensic applications. *Spectroscopy (Santa Monica)*, 30(8).
- Rodríguez, P. B., Tomé, F. V., & Lozano, J. C. (2012). Vertical distribution of natural radionuclides in soils. *EPJ Web of Conferences*, 24. <https://doi.org/10.1051/epjconf/20122405001>
- Ruan, H. D., Frost, R. L., Kloprogge, J. T., & Duong, L. (2002). Infrared spectroscopy of goethite dehydroxylation: III. FT-IR microscopy of in situ study of the thermal transformation of goethite to hematite. *Spectrochimica Acta - Part A Molecular and Biomolecular Spectroscopy*, 58(5). [https://doi.org/10.1016/S1386-1425\(01\)00574-1](https://doi.org/10.1016/S1386-1425(01)00574-1)

- Ruffell, A., & Donnelly, L. (2016). Forensic Geoscience Group - the first decade. In *Geoscientist* (Vol. 26, pp. 10–15).
- Ruffell, A., Pirrie, D., & Power, M. R. (2013). Issues and opportunities in urban forensic geology. *Geological Society Special Publication*, 384(1), 148–161. <https://doi.org/10.1144/SP384.19>
- Ruffell, A., & Wiltshire, P. (2004). Conjunctive use of quantitative and qualitative X-ray diffraction analysis of soils and rocks for forensic analysis. *Forensic Science International*, 145(1), 13–23. <https://doi.org/10.1016/j.forsciint.2004.03.017>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088). <https://doi.org/10.1038/323533a0>
- Ruppert, D. (2004). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. *Journal of the American Statistical Association*, 99(466). <https://doi.org/10.1198/jasa.2004.s339>
- Russell, S., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach, Global Edition 4th. In *Foundations* (Vol. 19).
- Salamuni, E., Ebert, H. D., da Silva Borges, M., Hasui, Y., Costa, J. B. S., & Salamuni, R. (2003). Tectonics and sedimentation in the Curitiba Basin, south of Brazil. *Journal of South American Earth Sciences*, 15(8). [https://doi.org/10.1016/S0895-9811\(03\)00013-0](https://doi.org/10.1016/S0895-9811(03)00013-0)
- Salvador, F. A. da S., Nogueira e Silva, M. P., de Oliveira Mascarenhas, R., & Rumbelsperger, A. M. B. (2019). The application of forensic geology to investigate the substitution of zinc ingots between China and Brazil. *Geological Society, London, Special Publications*, SP492-2018–2083. <https://doi.org/10.1144/sp492-2018-83>
- Sangwan, P., Nain, T., Singal, K., Hooda, N., & Sharma, N. (2020). Soil as a tool of revelation in forensic science: A review. In *Analytical Methods* (Vol. 12, Issue 43). <https://doi.org/10.1039/d0ay01634a>
- Santos, L. da R., Leandro, R., Fedalto, G., Spisila, A., Bahniuk, A. M., Siga Jr, O., & Cury, L. F. (2021). The Capiru Group: From passive margin to syn-orogenic units, implications for the evolution of the northern margin of the Curitiba microplate,

- Western Gondwana. *Journal of South American Earth Sciences*, 112, 103555. <https://doi.org/10.1016/J.JSAMES.2021.103555>
- Saye, S. E., & Pye, K. (2004). Development of a coastal dune sediment database for England and Wales: Forensic applications. *Geological Society Special Publication*, 232. <https://doi.org/10.1144/GSL.SP.2004.232.01.09>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. In *Neural Networks* (Vol. 61). <https://doi.org/10.1016/j.neunet.2014.09.003>
- SHAPIRO, S. S., & WILK, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3–4). <https://doi.org/10.1093/biomet/52.3-4.591>
- Shenggao, L. (2000). Lithological factors affecting magnetic susceptibility of subtropical soils, Zhejiang Province, China. *Catena*, 40(4). [https://doi.org/10.1016/S0341-8162\(00\)00092-8](https://doi.org/10.1016/S0341-8162(00)00092-8)
- Shimamoto, G. G., Terra, J., & Bueno, M. I. M. S. (2013). Use of portable x-ray fluorescence to discriminate brands of nail polishes: A potential forensic tool. *Journal of the Brazilian Chemical Society*, 24(5). <https://doi.org/10.5935/0103-5053.20130093>
- Siga Junior, O., Basei, M. A. S., Reis Neto, J. M., Machiavelli, A., & Harara, O. M. (1995). O Complexo Atuba: um cinturão paleoproterozoico intensamente retrabalhado no Neoproterozoico. *Boletim IG - Universidade de São Paulo, Instituto de Geociências*, 26. <https://doi.org/10.11606/issn.2316-8986.v26i0p69-98>
- Smale, D., & Trueman, N. A. (1969). Heavy Mineral Studies as Evidence in a Murder Case in Outback Australia. *Journal of the Forensic Science Society*, 9(3–4). [https://doi.org/10.1016/S0015-7368\(69\)70521-7](https://doi.org/10.1016/S0015-7368(69)70521-7)
- Sparks, R. S. J., Annen, C., Blundy, J. D., Cashman, K. v., Rust, A. C., & Jackson, M. D. (2019). Formation and dynamics of magma reservoirs. In *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* (Vol. 377, Issue 2139). <https://doi.org/10.1098/rsta.2018.0019>
- Stella, T. W. L., Swarup, S., See Suet Ning, M., Lim, N. Q. B. I., Phua Mun Lin, S., Tan Boon Jay, T., & Ghosh, S. (2020). Forensic Pedology: From Soil Trace Evidence to

- Courtroom. In *Soil Analysis: Recent Trends and Applications*. https://doi.org/10.1007/978-981-15-2039-6_16
- Stern, L. A., Webb, J. B., Willard, D. A., Bernhardt, C. E., Korejwo, D. A., Bottrell, M. C., McMahon, G. B., McMillan, N. J., Schuetter, J. M., & Hietpas, J. (2019). Geographic Attribution of Soils Using Probabilistic Modeling of GIS Data for Forensic Search Efforts. *Geochemistry, Geophysics, Geosystems*, 20(2), 913–932. <https://doi.org/10.1029/2018GC007872>
- Sugita, R., & Marumo, Y. (1996). Validity of color examination for forensic soil identification. *Forensic Science International*, 83(3). [https://doi.org/10.1016/S0379-0738\(96\)02038-5](https://doi.org/10.1016/S0379-0738(96)02038-5)
- Szelecz, I., Lösch, S., Seppey, C. V. W., Lara, E., Singer, D., Sorge, F., Tschui, J., Perotti, M. A., & Mitchell, E. A. D. (2018). Comparative analysis of bones, mites, soil chemistry, nematodes and soil micro-eukaryotes from a suspected homicide to estimate the post-mortem interval. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-017-18179-z>
- Szuszkiewicz, M., Grison, H., Petrovský, E., Szuszkiewicz, M. M., Gołuchowska, B., & Łukasik, A. (2021). Quantification of pedogenic particles masked by geogenic magnetic fraction. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-94039-1>
- Taghdis, S., Farpoor, M. H., Fekri, M., & Mahmoodabadi, M. (2021). Vertical distribution of magnetic susceptibility as affected by pedoenvironmental factors along an arid and semi-arid transect, Fars Province, Iran. *Studia Geophysica et Geodaetica*, 65(1). <https://doi.org/10.1007/s11200-020-1259-7>
- Testoni, S. A., Melo, V. F., Anne Dawson, L., Malakoski, J., Cunico, E., & Junqueira Neto, J. A. (2020). The Use of a Sequential Extraction Technique to Characterize Soil Trace Evidence Recovered from a Spade in a Murder Case in Brazil*. *Journal of Forensic Sciences*, 65(6). <https://doi.org/10.1111/1556-4029.14491>
- Testoni, S. A., Melo, V. F., Dawson, L. A., da Silva Salvador, F. A., & Kunii, P. A. (2019). Validation of a standard operating procedure (SOP) for forensic soils investigation

- in Brazil. *Revista Brasileira de Ciencia Do Solo*, 43. <https://doi.org/10.1590/18069657rbcs20190010>
- Testoni, S. A., Melo, V. F., Dawson, L. A., Salvador, F. A. S., & Pradel, L. v. (2019). Evaluation of forensic soil traces from a crime scene: robbery of a safety deposit box in Brazil. *Geological Society, London, Special Publications*. <https://doi.org/10.1144/sp492-2019-35>
- Thiede, D. S., & Vasconcelos, P. M. (2010). Paraná flood basalts: Rapid extrusion hypothesis confirmed by new $^{40}\text{Ar}/^{39}\text{Ar}$ results. *Geology*, 38(8). <https://doi.org/10.1130/G30919.1>
- Thompson, M. (2009). Portable X-ray fluorescence analysis. In *Royal Society of Chemistry*. www.rsc.org/amc
- Tighe, M., Forster, N., Guppy, C., Savage, D., Grave, P., & Young, I. M. (2018). Georeferenced soil provenancing with digital signatures. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-21530-7>
- Török, A., & Hajpál, M. (2005). Effect of Temperature Changes on the Mineralogy and Physical Properties of Sandstones. A Laboratory Study. *Restoration of Buildings and Monuments Bauinstandsetzen Und Baudenkmalpflege*, 11, No 4.
- United states department of agriculture. USDA. (1996). Soil survey laboratory methods manual. Soil Survey Investigations Report, No. 42. Ver. 3.0. *Soil Survey Investigations Report*.
- Vieira, K. T. P., & Fernandes, L. A. (2020). Análise faciológica e contexto deposicional do geossítio Bacia Sedimentar de Curitiba, nova seção-tipo para a Formação Guabirotuba. *Geologia USP. Série Científica*, 20(2). <https://doi.org/10.11606/issn.2316-9095.v20-165568>
- Viscarra Rossel, R. A., Minasny, B., Roudier, P., & McBratney, A. B. (2006). Colour space models for soil science. *Geoderma*, 133(3–4). <https://doi.org/10.1016/j.geoderma.2005.07.017>
- Wentworth, C. K. (1922). A Scale of Grade and Class Terms for Clastic Sediments. *The Journal of Geology*, 30(5). <https://doi.org/10.1086/622910>

- Werner, D., Burnier, C., Yu, Y., Marolf, A. R., Wang, Y., & Massonnet, G. (2019). Identification of some factors influencing soil transfer on shoes. *Science and Justice*, 59(6). <https://doi.org/10.1016/j.scijus.2019.07.004>
- Wills, S. A., Burras, C. L., & Sandor, J. A. (2007). Prediction of Soil Organic Carbon Content Using Field and Laboratory Measurements of Soil Color. *Soil Science Society of America Journal*, 71(2), 380–388. <https://doi.org/10.2136/sssaj2005.0384>
- Xu, X., Du, C., Ma, F., Shen, Y., & Zhou, J. (2020). Forensic soil analysis using laser-induced breakdown spectroscopy (LIBS) and Fourier transform infrared total attenuated reflectance spectroscopy (FTIR-ATR): Principles and case studies. *Forensic Science International*, 310. <https://doi.org/10.1016/j.forsciint.2020.110222>
- Yang, J., Wang, Y., Wang, J., & Hu, Y. (2020). Microscale Soil Chemistry of Heavy Metals : Research Process and Perspective. *Acta Pedologica Sinica*, 57(3). <https://doi.org/10.11766/trxb201908250445>
- Zeng, R., Rossiter, D. G., Zhao, Y. G., Li, D. C., & Zhang, G. L. (2020). Forensic soil source identification: comparing matching by color, vis-NIR spectroscopy and easily-measured physio-chemical properties. *Forensic Science International*, 317. <https://doi.org/10.1016/j.forsciint.2020.110544>

7 APÊNDICE 1

Na sequência, estão dispostos os dados brutos das análises realizadas em laboratório, referentes às amostras controle (1 a 232), questionadas (1S a 14S) e do horizonte B (com o código 'B', ex: 168B).

Ponto	UTM X	UTM Y	MS	K	U	Th	LE	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	Si-O-Si	Si-O-Fe	Si-O	Si-O-Al	Si-O-Si		
1	682580	7195773	0.014	2.1	2.4	9.4	93.57	5.1	1.23	0.0533	0.019	0.0032		0.0073	0.0048	0.0071		8	563.00	196	3.15	141	88	0.1296	0.005126	0.06715	0.0877	0.1063	0.2157		
2	682796	7196181	0.026	2.1	1.8	11.8	95.74	3.6	0.58	0.0265	0.027	0.027		0.0047	0.0036	0.0047		13	299.00	276	3.67	258	138	0.0794	0.036177	0.05577	0.05927	0.1319	0.2055		
3	682841	7196262	0.03	2.2	2.4	8.7	94.34	4.48	1.08	0.0488	0.018	0.0017		0.0025		0.005		12	533.00	213	3.35	177	102	0.09059	0.005732	0.03669	0.05927	0.06858	0.1607		
4	682767	7196566	0.027	2.2	2.4	10.9	96.25	2.89	0.73	0.0464	0.032	0.0014	0.03	0.0018	0.0041	0.0056		16	338.00	295	4.05	286	200	0.05422	0.009461	0.02935	0.03171	0.05783	0.1239		
5	682513	7196561	0.05	2.2	1.7	9.8	93.37	5.18	1.29	0.0481	0.033	0.0031		0.0023	0.0086	0.0033	0.0253	14	530.00	160	2.51	141	77	0.1491	0.0007963	0.05863	0.074437	0.08002	0.2385		
6	682561	7196857	0.046	2	2.1	11.1	94.89	3.55	1.44	0.063	0.036	0.004		0.006		0.0047		10	574.00	183	2.96	139	80	0.09821	0.004306	0.05279	0.08214	0.0696	0.2017		
7	682252	7197197	0.053	2	2.1	9.9	92.42	6.24	1.2	0.0507	0.036	0.003		0.003	0.0032	0.0035	0.0083		10	611.00	140	2.32	105	56	0.09171	0.001651	0.05071	0.08812	0.08974	0.1681	
8	682157	7197852	0.06	2.3	10.6	89.33	8.72	1.77	0.0687	0.031	0.0038	0.0141	0.0034	0.007	0.0041	0.0038	0.0028		8	645.00	276	2.97	117	64	0.1011	0.02244	0.06553	0.06953	0.12127	0.2127	
9	682753	7198956	0.153	2.1	1.9	11.9	90.7	7.88	1.27	0.0589	0.039	0.003		0.0061	0.0029	0.0039	0.0061	0.0029		8	417.00	169	2.46	135	101	0.07868	0.009471	0.05797	0.06346	0.09045	0.1668
10	681610	7198528	0.035	1.9	1.9	9	91.87	6.36	1.59	0.0585	0.052	0.0028	0.046	0.0026	0.0061	0.0052	0.0052		8	589.00	169	2.75	117	71	0.01035	0.001541	0.007616	0.00738	0.01133	0.02724	
11	681734	7199279	0.067	2.1	2.6	9.7	90.54	7.95	1.34	0.0599	0.062	0.0019	0.041	0.0041	0.0056	0.003	0.0066		12	465.00	117	1.78	101	65	0.02001	0.000864	0.01175	0.01302	0.02182	0.05514	
12	682156	7199444	1.55	2	1.8	10.9	80.9	14.61	4.1	0.0582	0.23	0.0024	0.08	0.0036	0.0031	0.0077	0.0053	10	565.00	177	2.85	137	79	0.09346	0.0009301	0.07827	0.07792	0.1274	0.2549		
13	682501	7199741	0.092	2.2	1.9	9.9	89.66	9.16	0.83	0.016	0.256	0.05	0.0063	0.0055	0.0113	0.0036	8	615.00	165	2.73	112	65	0.1105	0.003505	0.06501	0.07087	0.1092	0.2161			
14	681638	7199921	0.02	2.1	2	11.6	94.7	4.48	0.65	0.0263	0.051	0.022	0.025	0.0091	0.0072	0.0045	0.0169	0.0075	15	366.00	152	2.20	220	135	0.1156	0.01222	0.05683	0.05924	0.08764	0.14244	
15	681694	7200282	0.026	2	1.8	10.1	94.53	4.08	1.24	0.0382	0.041	0.0044	0.0066	0.005	0.0089	0.0032	15	340.00	341	4.68	230	2587	0.001595	0.1235	0.05884	0.05924	0.1959	0.4207			
16	681790	7200565	0.756	2.1	1.8	10.1	82.59	15.31	1.87	0.0411	0.092	0.0012	0.039	0.0018	0.0038	0.013	21	406.00	62	90	66	38	0.1046	0.003417	0.05647	0.06731	0.1196	0.2304			
17	681544	7201280	0.013	2	2.3	10.9	96.21	2.9	0.8	0.0352	0.01	0.0022	0.03	0.0021	0.0039	0.0037		15	357.00	374	520	352	246	0.2013	0.003289	0.1007	0.08812	0.1467	0.346		
18	682027	7201752	0.02	2.5	9.5	92.29	6.59	1	0.0334	0.016	0.0018	0.041	0.0039	0.0043	0.0034	0.0037		15	547.00	200	318	180	93	0.1983	0.003796	0.083307	0.09646	0.1462	0.2996		
19	682222	7201943	0.032	2.1	2.5	9.1	92.91	5.38	1.57	0.0706	0.01	0.0045	0.035	0.0021	0.0044	0.0046	0.0029		10	621.00	222	369	165	86	0.1086	0.002076	0.07093	0.09558	0.08764	0.2272	
20	682824	7202190	0.068	2	2.9	10	93.74	4.86	1.25	0.0449	0.032	0.0025	0.037	0.0054	0.0064	0.0066	0.0033	11	510.00	135	210	110	68	0.1017	0.002414	0.05118	0.06332	0.07957	0.1832		
21	682944	7202901	0.112	2.2	1.4	10.8	81.73	14.4	3.61	0.0571	0.005	0.0032	0.01	0.0092	0.0032	0.0058	0.0058	9	622.00	137	228	96	53	0.1315	0.00211	0.09764	0.1071	0.1695	0.2868		
22	682868	7202365	1.17	2.1	1.7	10.9	75.89	20.45	3.36	0.0534	0.104	0.0038	0.1	0.003	0.0031	0.0034	0.0037		8	585.00	120	195	83	51	0.1611	0.001046	0.02046	0.08784	0.1096	0.2204	
23	682702	7202026	0.039	2	2.6	8.6	93.14	5.31	1.45	0.0466	0.015	0.0032		0.0023	0.0072	0.0049	0.0049	0.0022	12	565.00	141	227	99	63	0.1341	0.003688	0.07408	0.0748	0.0753	0.1111	
24	682559	7201886	0.035	1.9	2.4	10.3	93.03	6.02	0.87	0.0362	0.0028	0.0049	0.026	0.0049	0.0045	0.0025	0.0025	12	503.00	230	354	192	117	0.1117	0.01431	0.04853	0.05687	0.08847	0.172		
25	682609	7201719	0.016	2.1	2.4	9.6	95.64	3.77	0.52	0.0292	0.015		0.006	0.003	0.003	0.003	0.003	15	370.00	208	292	195	134	0.1429	0.01672	0.08406	0.08448	0.118	0.2768		
26	682862	7201439	0.029	1.9	2.5	11.1	95.58	3.69	0.61	0.028	0.051	0.0016	0.022	0.0024	0.0016	0.0028	0.0016	12	318.00	245	331	222	171	0.16	0.002244	0.08007	0.08589	0.1319	0.2854		
27	682863	7201202	0.019	2.1	2.4	9.8	94.08	4.89	0.85	0.0218	0.037	0.0018	0.025	0.003	0.0034	0.0153	0.0109	9	471.00	197	298	157	107	0.228	0.00556	0.05556	0.1176	0.1722	0.3472		
28	681710	7202170	0.02	2.1	3	9	92.91	5.44	1.51	0.0547	0.008	0.0039	0.031	0.0027	0.0063	0.0052	0.0063	10	563.00	199	319	150	93	0.2748	0.001393	0.01086	0.1214	0.2155	0.4115		
29	681805	7202480	0.041	2.1	2.3	12.9	91.44	7.15	1.31	0.0396	0.008	0.002	0.029	0.0069	0.0046	0.0046	0.0059	9	578.00	217	352	157	94	0.2857	0.002551	0.1115	0.13238	0.23556	0.4195		
30	682103	7202962	0.435	2.1	2.7	9	88.43	9.95	1.42	0.0407	0.088	0.0016	0.023	0.0066	0.0066	0.0023	0.0017	10	489.00	70	108	57	37	0.1709	0.003818	0.1038	0.1236	0.1908	0.3401		
31	682119	7203155	0.049	2	2.7	11.3	92.9	5.88	1.06	0.0369	0.057	0.0022	0.04	0.039	0.0062	0.0045	0.0092	12	508.00	147	227	124	74	0.2299	0.003746	0.09273	0.09947	0.1615	0.3587		
32	681169	7201992	0.031	2	2.3	11.7	94.18	4.15	1.54	0.0556	0.015	0.0038	0.03	0.0025	0.0058	0.0042	0.0052	11	324.00	179	243	161	124	0.1468	0.000886	0.07498	0.0949	0.1394	0.2271		
33	680868	7202309	0.052	2.3	2.3	10	91.59	6.3	1.95	0.0528	0.02	0.0034	0.045	0.0045	0.0053	0.0064	0.0064	12	532.00	255	400	213	122	0.1612	0.0002932	0.1064	0.182	0.3034	0.4195		
34	681072	7202719	0.101	2.1	1.9	9.8	92.83	4.84	2.04	0.0348	0.103	0.0047	0.036	0.0053	0.0061	0.0056	0.0031	11	509.00	105	163	85	53	0.07627	0.003587	0.06622	0.08454	0.10341	0.2459		
35	680416	7202818	0.069	2.2	2.4	9.3	93.98	3.92	1.76	0.0483	0.178	0.0032	0.031	0.0058	0.0066	0.0034	0.0095	11	488.00	173	265	143	91	0.1839	0.002427	0.08213	0.09322	0.1121	0.289		
36	681557	7203109	0.914	2.2	1.9	94	84.99	12.27	2.43	0.0344	0.175	0.003	0.046	0.0015</																	

Ponto	UTM X	UTM Y	Si	K	U	Th	LE	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	Si-O-Si	Si-O-Fe	Si-O	Si-O-Al	Si-O-Si								
51	679540	720108	0,051	2,2	2,1	10,7	94,53	4,68	0,7	0,0175	0,046	0,024	0,0031	0,0032	0,004	0,0023	0,0043	0,004	0,0023	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043		
52	679219	720131	0,051	2,2	2,8	9,8	95,23	3,23	0,77	0,0175	0,047	0,024	0,0031	0,0032	0,004	0,0023	0,0043	0,004	0,0023	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043		
53	678966	720133	0,15	2,2	2,2	10,5	91,25	7,41	1,21	0,0214	0,025	0,019	0,044	0,0037	0,0044	0,0019	0,0214	0,0105	0,013	0,0022	0,0077	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027	0,0027
54	679618	720178	0,175	2,1	2,7	11	96,68	2,79	0,5	0,0105	0,038	0,026	0,0043	0,0043	0,0043	0,0041	0,0043	0,0043	0,0041	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043			
55	679996	720211	0,201	2,1	2,6	9,1	89,27	8,86	1,69	0,0432	0,038	0,035	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269				
56	680632	720167	0,036	2,1	2,5	11,1	97,05	2,48	0,41	0,0269	0,035	0,035	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269	0,0269				
57	680663	720146	0,402	2,1	2,4	11,4	91,69	6,92	1,25	0,0229	0,047	0,038	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236				
58	679979	720259	0,149	2,1	2	11,8	93,07	5,43	0,73	0,0303	0,04	0,0119	0,048	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041			
59	678909	719984	0,039	2	2,4	11	94,8	2,64	0,44	0,0164	0,033	0,035	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216	0,0216				
60	687731	719803	0,023	2	1,9	12	95,86	3,44	0,6	0,0171	0,064	0,038	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056	0,0056				
61	679507	719795	0,071	2,1	2,5	10,8	94,78	4,51	0,57	0,381	0,04	0,036	0,024	0,0077	0,0077	0,0045	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036			
62	680382	719736	0,073	2	2	10,8	90,24	7,93	1,66	0,0559	0,048	0,024	0,0046	0,0035	0,0085	0,0037	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036				
63	679628	719685	0,115	2,2	2,3	11,9	91,51	0,51	0,0184	0,438	0,0013	0,046	0,0036	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006	0,006				
64	679731	719651	0,027	2	2,7	12,5	96,81	2,74	0,31	0,0216	0,055	0,03	0,036	0,0058	0,0082	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077	0,0077				
65	680182	719602	0,029	1,9	2,4	10,7	93,8	4,3	1,47	0,0699	0,275	0,003	0,045	0,0058	0,0083	0,0034	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089	0,0089				
66	679715	719902	0,02	2	2,3	9,6	94,68	4,43	0,77	0,012	0,0018	0,031	0,0059	0,0118	0,0037	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032				
67	680049	719877	0,059	1,9	2,4	11,6	89,67	8,53	1,64	0,0471	0,032	0,0025	0,041	0,0062	0,012	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035	0,0035			
68	679807	719933	0,076	2,1	2,7	10,5	95,15	4,05	0,71	0,017	0,055	0,038	0,0053	0,0053	0,0053	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032	0,0032			
69	679058	7199312	0,039	2,2	2,8	10,9	96,03	3,16	0,72	0,0209	0,034	0,025	0,0022	0,0068	0,0068	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099	0,0099			
70	679745	719972	0,019	2	2,9	10,2	96,3	3,19	0,44	0,018	0,039	0,028	0,0028	0,0028	0,0028	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025			
71	679069	720061	0,061	2,1	2,3	9,6	95,23	3,43	0,49	0,0201	0,048	0,0201	0,0055	0,0072	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055				
72	679199	720164	0,034	2,1	2,4	11,4	95,2	4,13	0,58	0,0201	0,048	0,0201	0,0055	0,0072	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055	0,0055				
73	679502	720320	0,031	2,1	1,6	11,1	97,31	2,2	0,41	0,0153	0,055	0,036	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236				
74	679040	720266	0,049	2,2	1,5	11,1	92,01	6	1,84	0,0487	0,029	0,0031	0,05	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041	0,0041			
75	678621	720286	0,048	2	2,2	10,2	89,43	8,07	2,31	0,0507	0,041	0,0033	0,05	0,0056	0,0084	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031	0,0031			
76	677880	720306	0,983	2,1	2,4	9,7	85,52	12,2	1,95	0,0338	0,2	0,017	0,033	0,003	0,0042	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022	0,0022			
77	678220	720268	0,207	2,2	10,4	91,12	6,87	1,8	0,089	0,089	0,015	0,05	0,0208	0,0016	0,041	0,003	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044	0,0044			
78	677490	720193	0,031	2	2,1	9,7	96,44	3,06	0,46	0,0236	0,013	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236	0,0236					
79	677333	720182	0,021	2,2	2,2	9,9	97,29	2,32	0,31	0,0242	0,044	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244	0,0244					
80	677283	720154	0,083	2,1	2,8																																

Ponto	UTM X	UTM Y	Si	K	U	Th	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	Si-O-Si	C=O	Si-O-Fe	Si-O	Si-O-Al	Si-O-Si
100	677695	7196685	0,071	2,2	1,8	9,4	90,74	8,06	1,05	0,035	0,056	0,041	0,005		0,0044	0,0057	11	545,00	313	496	253	146	0,1748	0,004286	0,09508	0,00981	0,1448	0,2928	
101	678903	7195555	0,181	2,2	2,8	10,5	85,23	12,65	1,8	0,0444	0,171	0,0021	0,07	0,0066	0,0086	0,0009	10	587,00	182	296	136	77	0,1531	0,0093	0,0909	0,1093	0,1712	0,321	
102	676963	7195969	0,042	2	2,1	8,8	92,67	6,64	0,52	0,0463	0,078	0,039	0,0047	0,005	0,0034	0,0036	11	581,00	294	476	227	126	0,188	0,002344	0,1094	0,1129	0,1663	0,3044	
103	676754	7196237	0,621	2	2,8	9,1	84,71	13,3	1,67	0,0331	0,168	0,0015	0,08	0,0058	0,0035	0,0079	0,015	8	597,00	155	254	108	64	0,1044	0,002407	0,08688	0,09378	0,1446	0,2876
104	676460	7196742	0,019	2	1,8	11,2	93,68	5,49	0,69	0,0644	0,018	0,0029	0,029	0,0057	0,0096	0,0053	13	483,00	317	482	274	168	0,1334	0,004058	0,09042	0,09421	0,1311	0,2407	
105	676197	7197301	0,548	1,9	2,4	9,1	81,78	16,31	1,53	0,0423	0,18	0,0028	0,07	0,0036	0,0025	0,0069	0,023	9	596,00	154	253	111	64	0,1227	0,001128	0,09782	0,1091	0,1594	0,259
106	676601	7197429	1,01	2	2,2	10,2	79,73	17,67	2,18	0,044	0,25	0,0025	0,09	0,0055	0,0031	0,0055	0,0145	9	614,00	195	322	140	77	0,09607	0,002241	0,08988	0,09749	0,1509	0,266
107	676907	7197146	0,391	2,1	1,7	10,6	88,83	9,91	0,98	0,0326	0,136	0,0023	0,058	0,0062	0,0044	0,0032	0,0157	12	527,00	281	150	87	1496	0,001941	0,09333	0,1425	0,2848	0,321	
108	676802	7197570	0,111	2,1	2,4	10,3	95,75	3,66	0,51	0,03202	0,039	0,0038	0,0055	0,0078	0,0055	0,0078	13	362,00	345	481	316	225	0,1576	0,001941	0,09784	0,1019	0,1486	0,2893	
109	677036	7197800	0,561	2,2	1,9	9,6	84,42	14,45	0,83	0,0175	0,185	0,0014	0,063	0,0085	0,0015	0,0054	0,0247	9	507,00	170	263	130	86	0,0985	0,003587	0,08815	0,08778	0,1387	0,2635
110	677669	7198244	0,062	2	9,4	93,66	5,54	0,57	0,0271	0,112	0,0017	0,033	0,0098	0,0071	0,0048	0,0102	10	573,00	254	410	192	111	0,2014	0,003056	0,09156	0,0979	0,1573	0,3265	
111	677189	7200444	0,009	2,1	1,5	11,8	95,97	3,31	0,56	0,0747	0,017	0,0031	0,039	0,0034	0,0087	0,0052	0,0055	12	507,00	319	493	270	161	0,1506	0,002977	0,03323	0,03473	0,10457	0,2275
112	676974	7199885	0,022	2,1	2,3	9,1	94,99	4	0,94	0,0347	0,018	0,0029	0,0045	0,0025	0,0045	0,0025	13	439,00	292	431	257	168	0,1892	0,004758	0,07754	0,07468	0,1068	0,2714	
113	676579	7199325	0,023	2,2	2,3	10,3	94,55	4,49	0,76	0,0249	0,134	0,0017	0,031	0,0039	0,0039	0,0059	0,0059	13	472,00	253	382	219	137	0,277	0,004199	0,0648	0,1048	0,1757	0,3829
114	676340	7198742	0,304	1,9	2,5	10,6	91,22	7,06	1,37	0,0298	0,211	0,0014	0,035	0,0054	0,0054	0,0065	9	594,00	219	358	159	91	0,1333	0,00105	0,09352	0,08865	0,111	0,2616	
115	675686	7198561	0,032	2,1	2,2	10,7	97,76	1,81	0,36	0,0185	0,038	0,0014	0,0021	0,0021	0,0021	0,0044	14	368,00	390	546	361	252	0,05453	0,002977	0,03323	0,03473	0,10457	0,2061	
116	675162	7198656	0,022	2	9,4	95,97	3,15	0,75	0,0311	0,08	0,0018	0,0044	0,0068	0,0034	0,0068	0,0041	14	409,00	329	475	299	199	0,14772	0,006119	0,07307	0,06966	0,09901	0,2413	
117	674888	7198965	0,022	2	9,8	93,63	5,38	0,89	0,0307	0,024	0,0022	0,024	0,004	0,0037	0,0037	0,0037	13	439,00	292	431	257	168	0,1892	0,005579	0,0751	0,08345	0,158	0,2999	
118	674671	7198378	0,016	2	1,7	9,1	91,53	7,41	0,91	0,0244	0,07	0,002	0,034	0,0025	0,0037	0,0034	0,0048	12	493,00	258	395	217	134	0,221	0,002247	0,07988	0,1006	0,169	0,3445
119	675835	7198162	0,078	2	2	10,3	90,37	8,41	1,02	0,0333	0,059	0,0023	0,039	0,0075	0,0054	0,0034	0,0123	10	598,00	238	390	181	98	0,08866	0,00232	0,05173	0,05973	0,09403	0,1778
120	675810	7197973	0,078	1,9	2,9	8,9	95,87	1,06	0,0322	0,0252	0,0025	0,035	0,0016	0,016	0,0108	0,0078	11	534,00	201	301	161	1276	0,000593	0,0366	0,1031	0,1669	0,2763		
121	675701	7196767	1,09	1,9	2,1	8,5	86,33	12,56	0,85	0,022	0,138	0,0013	0,059	0,0056	0,0018	0,0036	0,0187	10	519,00	178	278	140	88	0,09678	0,00464	0,08386	0,08359	0,1242	0,2628
122	675447	7196600	0,006	2,2	2	11,6	98,39	1,44	0,12	0,0198	0,009	0,0046	0,0085	0,0035	0,0046	0,0085	0,0048	15	287,00	522	675	508	394	0,1936	0,003267	0,1078	0,1076	0,1631	0,3104
123	675639	7195963	0,807	2,1	1,9	10,8	86,24	11,87	1,63	0,0441	0,123	0,0026	0,07	0,0048	0,0044	0,0067	0,0158	10	599,00	219	359	161	90	0,1098	0,005064	0,09609	0,0869	0,1122	0,2755
124	675324	7195602	0,012	2,1	1,8	11	96,31	3,21	0,39	0,0195	0,051	0,0039	0,0072	0,0043	0,0092	0,0039	0,0072	14	444,00	339	502	307	193	0,1876	0,003713	0,09094	0,09709	0,1346	0,2844
125	674597	7195410	0,156	2,2	2,4	9	82,06	15,57	2,1	0,0321	0,058	0,0019	0,08	0,0055	0,0041	0,0134	0,0035	8	602,00	179	294	123	73	0,1224	0,002496	0,08816	0,09861	0,1554	0,2595
126	674919	7196975	0,009	2,1	2,2	9,5	90,91	8,19	0,81	0,0201	0,021	0,016	0,021	0,034	0,0063	0,0035	9	504,00	232	358	177	118	0,191	0,0001791	0,1171	0,1208	0,1982	0,3581	
127	674452	7195971	0,023	2,2	2,1	8,7	95,32	4	0,52	0,0218	0,108	0,0051	0,0074	0,0046	0,0086	0,0046	12	447,00	357	576	338	220	0,183	0,005026	0,10108	0,1065	0,1499	0,2842	
128	673584	7196190	0,957	2,1	1,7	9,5	87,93	9,92	1,73	0,0396	0,267	0,0021	0,06	0,0069	0,0084	0,0032	0,0121	9	564,00	161	259	117	72	0,1261	0,002044	0,08754	0,07541	0,10419	0,2676
129	674150	7196555	0,117	2	2,3	9,5	87,73	10,36	1,67	0,0348	0,048	0,0026	0,07	0,018	0,0037	0,0041	0,0064	10	579,00	230	372	175	99	0,1224	0,00429	0,0766	0,07868	0,1194	0,2697
130	674081	7196953	0,017	2,1	2,3	9,6	94,71	4,64	0,49	0,0182	0,083	0,0104	0,0085	0,0035	0,0096	0,0085	11	450,00	264	393	224	149	0,1265	0,005146	0,07745	0,0834	0,1176	0,2711	
131	674620	7197223	0,044	2	2,8	8,9	91,27	7,62	0,91	0,0254	0,08	0,038	0,0097	0,0049	0,007	0,007	0,0049	11	551,00	263	418	213	121	0,1765	0,001166	0,1065	0,1151	0,1713	0,3134
132	674927	7197615	0,022	1,9	2,2	9,6	89,51	9,76	0,6	0,0183	0,038	0,0013	0,0101	0,0046	0,0058	0,0034	10	538,00	243	383	187	115	0,2217	0,003207	0,1138	0,1225	0,2071	0,385	
133	673673	7197698	0,004	2,2	2,6	10,2	95,01	4,33	0,59	0,0116	0,03	0,0016	0,015	0,0016	0,003	0,003	13	211,00	371	461	355	300	0,1986	0,002122	0,1081	0,09005	0,1347	0,3507	
134	673252	7198138	0,008	2,2	1,1	10,1	94,1	5,07	0,73	0,0311	0,02	0,0018	0,034	0,0032	0,0035	0,0026	14	334,00	293	401	274	200	0,1629	0,003472	0,07571	0,087879	0,1355	0,2878	
135	673299	7198585	0,023	2,2	10,1	94,12	5,28	0,52	0,015	0,028	0,0026	0,0035	0,0046	0,0046	0,0039	0,0039	11	450,00	264	393	224	149	0,1292	0,0					

Ponto	UTM X	UTM Y	Si	K	U	Th	LE	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	Si-O-Si	C=O	Si-O-Fe	Si-O-Al	Si-O-Si	
150	676294	7201486	0.034	1.9	2.3	10.3	92.75	6.31	0.82	0.0323	0.037	0.0031	0.03	0.0103	0.0038	0.008	0.0041	8	558.00	147	239	104	62	0.06529	0.002276	0.03341	0.03336	0.05024		
151	675139	7201139	0.051	2	2	10.7	94.11	4.98	1.54	0.0317	0.092	0.0021	0.041	0.0162	0.0044	0.004	0.004	9	459.00	157	235	125	87	0.07226	0.002097	0.02761	0.06079	0.05111		
152	675288	7200444	0.331	2	2.1	10.8	91.07	7.21	0.51	0.0225	0.051	0.022	0.0043	0.0049	0.0049	0.0037	0.0047	11	437.00	184	271	157	106	0.1183	0.002374	0.0615	0.06079	0.0756		
153	675190	7200154	0.041	2.1	2.3	8.7	95.86	3.52	0.68	0.0289	0.045	0.0027	0.023	0.0158	0.0058	0.004	0.0158	10	524.00	271	423	210	132	0.1306	0.0007454	0.06709	0.05605	0.05768		
154	674900	7200292	0.031	2	2.4	9.2	94.9	4.25	0.68	0.0289	0.045	0.0027	0.023	0.0158	0.0058	0.004	0.0158	10	482.00	177	269	141	94	0.1109	0.002492	0.05434	0.05511	0.0582		
155	675130	7200138	0.031	1.9	1.6	10.1	94.49	4.68	0.73	0.0226	0.024	0.0016	0.039	0.0028	0.0047	0.0041	0.0028	10	482.00	177	269	141	94	0.1109	0.002492	0.05434	0.05511	0.1925		
156	675924	7200598	0.097	2.2	2.2	8.1	87.57	10.17	2.08	0.0506	0.049	0.0036	0.06	0.006	0.0049	0.0045	0.0065	8	624.00	176	294	122	68	0.05311	0.004406	0.04406	0.04406	0.05531		
157	676279	7200744	0.823	2	1.8	10.5	86.86	11.04	1.53	0.0317	0.092	0.0021	0.041	0.0162	0.0044	0.004	0.0044	9	525.00	155	180	86	56	0.07729	0.002165	0.03584	0.04841	0.06367		
158	676699	7200530	0.266	2.2	2.2	10.6	9.06	6.92	1.83	0.0323	0.065	0.0039	0.06	0.0209	0.0052	0.0061	0.0049	0.0068	10	583.00	220	357	164	94	0.1569	0.001017	0.07955	0.07598	0.1088	
159	673225	7195284	0.097	2.1	2.4	10.4	93.38	5.6	0.82	0.0458	0.051	0.0041	0.051	0.0045	0.0074	0.007	0.0093	0.0032	11	448.00	234	347	197	132	0.1726	0.0003603	0.0876	0.09218	0.1324	
160	673593	7195440	0.019	2	2.3	11.4	95.37	3.98	0.48	0.0249	0.068	0.003	0.033	0.0046	0.0165	0.0066	0.0093	0.003	13	115.00	178	259	160	107	0.1272	0.002418	0.04284	0.06031	0.07785	
161	672741	7195336	0.042	2.3	1.8	11.5	93	6.12	0.68	0.0279	0.094	0.0026	0.025	0.0082	0.0092	0.0035	0.0085	0.0073	11	481.00	160	243	131	85	0.1342	0.0007122	0.06137	0.07055	0.09714	
162	672274	7196513	0.02	2.1	1.9	10.4	93.63	5.58	0.66	0.0251	0.055	0.002	0.034	0.0037	0.0054	0.0038	0.0037	13	368.00	303	425	275	196	0.1441	0.00208	0.07681	0.07284	0.108		
163	672992	7196696	0.083	2	3	10.2	93.41	5.73	0.72	0.0216	0.062	0.0018	0.038	0.0033	0.0057	0.0047	0.0052	0.0052	11	516.00	252	392	203	125	0.1606	0.005448	0.08048	0.08648	0.1061	
164	672520	7197033	0.066	1.9	3	10.3	94.98	4.34	0.6	0.0214	0.038	0.0032	0.0081	0.0032	0.007	0.007	0.007	0.007	11	476.00	175	265	147	94	0.1505	0.002817	0.06933	0.07883	0.09248	
165	672252	7197380	0.093	2.1	1.7	11.4	93.86	5.14	0.82	0.0351	0.062	0.0029	0.034	0.0028	0.0089	0.0051	0.0099	0.0032	12	535.00	250	393	208	119	0.1543	0.0006675	0.07736	0.07452	0.1044	
166	671657	7197635	1.35	2.2	1.9	10.2	85.18	13.65	0.9	0.0324	0.135	0.0029	0.059	0.064	0.0046	0.0051	0.007	0.0173	9	557.00	165	264	124	75	0.09467	0.003894	0.07344	0.07005	0.09592	
167	671479	7197907	0.852	2.2	2.1	9.6	78.74	18.78	2.11	0.0328	0.143	0.0022	0.13	0.009	0.004	0.007	0.03	0.0238	8	612.00	146	241	98	58	0.09285	0.003412	0.07118	0.08388	0.1292	
168	671316	7198124	0.437	2	3.1	8.8	91.35	7.79	0.69	0.026	0.085	0.0026	0.029	0.0045	0.0048	0.001	0.0125	0.01	11	500.00	183	282	149	94	0.07564	0.0113	0.04629	0.05446	0.07978	
169	671190	7198404	0.063	2.1	2.5	10.6	93.57	5.58	0.72	0.0568	0.019	0.0027	0.036	0.0021	0.0024	0.0058	0.0051	0.0044	12	360.00	230	345	215	115	0.1834	0.0006675	0.07736	0.07452	0.1044	
170	671501	7199233	0.151	2.1	1.8	91.93	6.79	3.77	0.52	0.0443	0.095	0.0023	0.047	0.0045	0.0051	0.0032	0.0032	13	464.00	234	358	207	131	0.1051	0.0003715	0.06764	0.06471	0.1099		
171	671581	7198382	0.01	2.4	9.2	94.7	3.77	0.57	0.0448	0.027	0.0029	0.04	0.0029	0.0043	0.0041	0.0021	0.0029	14	415.00	324	470	299	194	0.159	0.0003643	0.08678	0.07684	0.1026		
172	671748	7198616	0.06	2.1	1.9	11.2	89.46	8.18	2.18	0.0652	0.028	0.0038	0.05	0.0034	0.0051	0.005	0.0066	0.0062	13	491.00	288	440	247	150	0.1009	0.0002383	0.07695	0.07889	0.1003	
173	673993	7201373	0.049	2.2	1.9	10.1	94.78	4.14	0.88	0.0455	0.088	0.003	0.041	0.0025	0.0077	0.0053	0.0053	0.0053	12	460.00	255	382	221	141	0.1465	0.002992	0.07451	0.07478	0.1071	
174	673705	7201648	0.043	2.1	1.8	9.4	94.66	4.21	0.97	0.0394	0.05	0.036	0.054	0.0057	0.036	0.036	0.054	0.0057	12	448.00	235	349	201	133	0.06345	0.005646	0.03729	0.04315	0.1395	
175	673420	7201755	0.031	2	10.3	94.6	4.24	1.02	0.3558	0.052	0.035	0.038	0.023	0.047	0.026	0.026	0.024	13	438.00	245	361	214	141	0.1051	0.0009924	0.04378	0.05224	0.06681		
176	673156	7202058	0.058	2.1	2.8	10.2	93.29	5.35	1.22	0.0375	0.054	0.0024	0.026	0.03	0.048	0.0052	0.0034	0.0051	12	447.00	240	356	206	136	0.16046	0.0008233	0.03924	0.05607	0.06807	
177	673507	7202203	1.047	2.1	2.6	9	1.35	0.47	0.3668	0.003	0.11	0.0082	0.003	0.0091	0.0192	0.10	0.067.00	10	567.00	151	243	117	67	0.06091	0.0001591	0.05291	0.06071	0.1593		
178	673862	7202295	1.448	2	1.6	11.5	90.77	7.36	1.7	0.0352	0.072	0.0025	0.04	0.0036	0.0036	0.0053	0.0053	0.0053	12	416.00	251	364	220	150	0.09145	0.02141	0.05556	0.06445	0.1011	
179	672768	7202171	0.042	2.1	2.6	9.4	96.63	2.65	0.62	0.0232	0.043	0.0031	0.025	0.0031	0.0031	0.0046	0.0046	0.0046	13	391.00	306	437	279	191	0.071	0.01944	0.04309	0.04319	0.1395	
180	672243	7202271	0.116	2.1	1.9	11.5	92.04	6.33	1.47	0.0449	0.051	0.0029	0.045	0.0035	0.0063	0.0063	0.0063	0.0063	10	557.00	141	225	109	64	0.24345	0.0001587	0.1223	0.113	0.1748	
181	672203	7201911	0.065	2.1	2.3	10.3	89.49	8.46	1.84	0.0555	0.066	0.0041	0.06	0.0033	0.0075	0.0043	0.0056	0.0056	11	558.00	188	300	148	85	0.08622	0.0003831	0.06582	0.074	0.1942	
182	671982	7201438	0.135	2.1	2.6	10.6	92.79	5.65	1.4	0.0433	0.07	0.0024	0.029	0.0058	0.0058	0.0058	0.0058	0.0058	12	452.00	244	363	211	137	0.10934	0.007497	0.05166	0.05628	0.1836	
183	671157	7200980	0.108	2.1	2.3	9.9	86.89	10.88	2.03	0.0664	0.024	0.0064	0.0064	0.0031	0.0064	0.0068	0.0068	0.0068	7	673.00	134	231	83	45	0.1082	0.0004173	0.08884	0.106	0.1548	
184	672105	7200668	0.048	2.3	2.2	9.5	9.3	9.03	5.97	0.93	0.0216	0.028	0.0017	0.0017	0.0044	0.0044	0.0051	0.0051	0.0051	11	518.00	239	372	196	118	0.13402	0.003064	0.04202	0.04401	0.1742
185	672892	7201152	0.055	2	1.9	11.5	94.84	4.03	1.02	0.0315	0.06	0.0022	0																	

Ponto	UTM X	UTM Y	SI	K	U	Th	LE	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	Si-O-Si	C=O	Si-O-Fe	Si-O	Si-O-Al	Si-O-Si					
200	672536	7200189	0,041	2,2	9,2	94,87	4,43	0,54	0,0277	0,065	0,0016	0,024	0,0053	0,0044	0,0033	0,0065	0,0031	10	532,00	163	256	125	78	0,1642	0,003375	0,05896	0,06907	0,08085	0,2622						
201	671645	7200089	0,441	2,1	2,5	9,73	9,83	2,19	0,0422	0,094	0,0049	0,019	0,08	0,0049	0,0049	0,0055	0,0062	0,0045	0,004	11	502,00	216	332	177	140	0,09601	0,005774	0,04762	0,0558	0,07137	0,1203				
202	672401	7202613	0,053	2	2,9	10,3	94,55	0,59	0,73	0,0742	0,0044	0,0029	0,025	0,0062	0,0045	0,0045	0,0057	0,003	0,006	10	583,00	192	312	147	82	0,1172	0,002344	0,06155	0,07333	0,114	0,2218				
203	672699	7202704	0,205	2,2	2	11	88,71	9,16	1,94	0,0513	0,046	0,0029	0,07	0,0043	0,0037	0,003	0,0057	0,0167	0,0167	10	603,00	177	291	131	72	0,1159	0,0008422	0,06645	0,08089	0,1274	0,2335				
204	673149	7203133	0,962	2,2	2,3	10,7	88,77	9,41	1,56	0,0225	0,114	0,09	0,0057	0,0052	0,0042	0,0087	0,0052	0,0035	0,0053	15	418,00	213	310	198	127	0,1132	0,001003	0,061	0,0555	0,05948	0,1954				
205	672155	7202487	0,027	2	2,3	9,7	95,79	3,16	0,92	0,0449	0,021	0,0034	0,033	0,0042	0,0087	0,0052	0,0035	0,0046	0,0035	0,0035	15	382,00	302	428	285	191	0,07378	0,0233	0,03451	0,04442	0,06799	0,1483			
206	671695	7202566	0,033	2,1	2,3	11	96,66	2,77	0,49	0,0229	0,023	0,0016	0,021	0,0034	0,0035	0,0046	0,0045	0,003	0,0068	0,0067	0,0068	14	354,00	231	321	215	153	0,04961	0,01261	0,02687	0,04474	0,0607	0,1056		
207	671556	720215	1,6	2,7	10,8	96,15	3,04	0,71	0,0501	0,037	0,0018	0,02	0,0045	0,0045	0,0045	0,0045	0,0056	0,0052	0,0052	0,0113	13	427,00	225	329	198	132	0,1441	0,003769	0,05846	0,07394	0,1004	0,2741			
208	670972	7202718	0,327	2	2	10	92,29	6,64	0,77	0,0212	0,0202	0,0015	0,04	0,0056	0,0056	0,0062	0,0062	0,0062	0,0062	0,0062	0,0163	0,0075	13	459,00	287	429	254	159	0,087	0,004597	0,06154	0,07356	0,1117	0,1972	
209	670781	7202848	0,057	2	2	10,7	96,39	3,19	0,36	0,0128	0,024	0,0036	0,024	0,0036	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	0,0163	0,0075	13	376,00	173	245	162	111	0,06227	0,0171	0,04641	0,07625	0,10412	0,1412
210	670510	7201951	0,434	2,1	2,4	10,7	97,33	2,32	0,24	0,0081	0,017	0,0054	0,0074	0,0074	0,0074	0,0074	0,0074	0,0074	0,0074	0,0074	0,0074	0,0075	13	459,00	287	429	254	159	0,087	0,004597	0,06154	0,07356	0,1117	0,1972	
211	671085	7202149	0,102	2,1	2,6	9,4	93,32	4,92	1,49	0,0458	0,043	0,0045	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0043	0,0037	10	510,00	225	346	180	115	0,1355	0,004687	0,06757	0,07073	0,08712	0,2435	
212	671687	7201736	0,054	2,1	2,3	10,2	90,28	7,72	1,83	0,0671	0,038	0,0036	0,044	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	0,0036	9	600,00	210	345	154	86	0,07574	0,000539	0,05325	0,05894	0,07692	0,1568	
213	671320	7201191	0,14	2	2,5	10,9	90,41	7,9	1,42	0,0546	0,035	0,0056	0,0052	0,0052	0,0034	0,0034	0,0034	0,0034	0,0034	0,0034	0,0034	0,0034	12	449,00	184	274	160	104	0,1256	0,0009653	0,05075	0,06434	0,0746	0,1046	
214	671534	7200615	0,056	2,3	2,1	10,7	97,53	2,1	0,3	0,0118	0,027	0,018	0,0019	0,0019	0,0038	0,0038	0,0038	0,0038	0,0038	0,0038	0,0038	0,0038	16	301,00	410	546	396	293	0,05553	0,004664	0,02747	0,03884	0,06436	0,1117	
215	671117	7200657	0,287	2,1	2,6	9,9	88,77	9,51	1,53	0,0224	0,051	0,1	0,0038	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	8	638,00	156	263	133	77	0,107	0,09281	0,01031	0,02735	0,09195	0,1462
216	670520	7201171	0,847	2,1	1,9	9,1	84,29	13,33	2,1	0,0347	0,154	0,0022	0,047	0,005	0,0042	0,0042	0,0042	0,0042	0,0042	0,0042	0,0042	0,0042	10	424,00	125	323	183	105	0,1462	0,004463	0,05653	0,06443	0,09438	0,1999	
217	670998	7199911	0,04	2,2	10,9	94,92	4,46	0,51	0,0257	0,039	0,002	0,025	0,0031	0,0031	0,0031	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	9	584,00	209	339	151	89	0,2262	0,0005639	0,09343	0,09745	0,1371	0,3726	
218	670874	7199061	0,07	2,1	2,1	10,4	90,81	7,54	1,47	0,0586	0,028	0,0017	0,06	0,0039	0,0055	0,0055	0,0037	0,0037	0,0037	0,0037	0,0037	0,0037	0,0037	10	424,00	125	323	183	105	0,1462	0,004466	0,056502	0,06524	0,09745	0,1901
219	680791	7195030	0,026	2,1	2,5	9,7	93,38	4,77	1,38	0,0689	0,043	0,004	0,032	0,0056	0,0085	0,0085	0,0085	0,0085	0,0085	0,0085	0,0085	0,0085	11	512,00	208	323	172	104	0,143	0,004117	0,06385	0,06037	0,08117	0,2534	
220	681337	7195100	0,162	2,1	2,1	9,38	5,43	1,08	0,0406	0,026	0,0026	0,0026	0,0054	0,0067	0,0067	0,0067	0,0067	0,0067	0,0067	0,0067	0,0067	0,0067	10	522,00	153	239	120	77	0,1660	0,00154	0,05653	0,06502	0,09602	0,1999	
221	680791	7195267	0,035	2,1	2,2	9,4	92,84	5,48	1,4	0,0602	0,123	0,0039	0,044	0,0059	0,0076	0,0076	0,005	0,005	0,005	0,005	0,005	0,005	0,005	9	488,00	128	315	195	113	0,1777	0,005607	0,06532	0,06532	0,09153	0,1953
222	681167	7195588	0,039	2	3	8,6	90,8	7,14	1,83	0,0642	0,101	0,0045	0,04	0,0033	0,008	0,008	0,0057	0,0077	0,0032	0,0032	0,0032	0,0032	0,0032	9	560,00	162	259	119	73	0,1171	0,006036	0,06286	0,0811	0,101	0,233
223	681677	7196497	0,056	1,9	2,9	11,2	93,93	4,59	1,33	0,0519	0,025	0,0028	0,04	0,0022	0,0047	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	10	531,00	248	389	196	119	0,1057	0,004669	0,0717	0,07242	0,08331	0,2217	
224	681717	7200750	0,083	2,1	1,8	8,9	95,03	4,03	0,76	0,0205	0,092	0,0016	0,039	0,0039	0,0058	0,0058	0,0039	0,0039	0,0039	0,0039	0,0039	0,0039	0,0039	11	512,00	208	323	172	104	0,143	0,004117	0,06385	0,06037	0,08117	0,2534
225	681767	7202252	0,04	2,1	2,4	9,8	96,38	3,1	0,46	0,0208	0,024	0,0026	0,035	0,0049	0,039	0,039	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	12	483,00	274	417	234	145	0,1758	0,002019	0,07576	0,07201	0,103	0,2833
226	681704	7202241	0,024	2,1	2	9,9	86,31	3,01	0,49	0,039	0,03	0,0026	0,035	0,0049	0,039	0,039	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	0,0062	12	455,00	141	211	122	79	0,2454	0,03407	0,06352	0,06532	0,09153	0,1953
227	678930	7202364	2,01	2,5	9,6	82,13	15,71	1,68	0,0411	0,29	0,0036	0,1	0,018	0,0084	0,0084	0,0024	0,0024	0,0024	0,0024	0,0024	0,0024	0,0024	11	447,00	201	299	171	114	0,09864	0,02996	0,09171	0,1004	0,1407	0,2669	
228	675657	7201341	2,19	2,1	9,7	90,31	8,45	1,11	0,0309	0,029	0,0015	0,048	0,0025	0,0048	0,0048	0,0048	0,0048	0,0048	0,0048	0,0048	0,0048	0,0048	9	637,00	170	285	121	63	0,1055	0,003428	0,065086	0,08185	0,104	0,2224	
229	674401	7200840	0,022	2,1	10,6	95,41	3,74	0,75	0,0336	0,047	0,0029	0,047	0,0029	0,0064	0,0064	0,0035	0,0045	0,0045	0,0045	0,0045	0,0045	0,0045	10	555,00	275	324	272	240	0,1399	0,002747	0,08034	0,066161	0,06994		

Ponto	UTM X	UTM Y	K	U	Th	Fe	Ti	Zr	Mn	Nb	V	Ni	Pb	Bi	Zn	Cu	H	S	L	R	G	B	
198	682222	7201943	0,026	2,2	2,0	10,8	93,31	5,03	1,5	0,0587	0,009	0,0042	0,028	-	0,007	0,0041	0,0275	0,0155	13	482	183	278	
248	682559	7201886	0,036	2,0	2,4	12,5	95,2	4,03	0,69	0,0256	0,019	0,0019	0,028	-	0,0062	-	0,0028	-	11	547	179	284	
288	681710	7202170	0,024	2,3	2,6	10,0	92,2	6,32	1,37	0,0498	-	0,003	0,049	0,0025	0,0053	0,0062	0,0047	-	10	548	181	288	
298	681805	7202490	0,027	2,2	3,1	10,8	91,61	7,14	1,13	0,0377	0,009	0,0035	0,037	0,0023	0,0066	0,0057	0,0057	0,0028	9	599	197	232	
488	680771	7200274	0,020	2,2	2,5	10,0	94,01	5,09	0,82	0,0302	0,009	0,0024	0,027	-	0,0038	-	-	13	444	301	445	264	
548	679618	7201788	0,416	2,2	1,8	11,9	93,55	5,57	0,8	0,0271	0,012	0,0026	0,026	-	0,0061	0,005	-	0,0033	10	494	309	473	
818	677890	7201167	0,084	1,9	2,7	8,8	91,78	6,6	1,5	0,0287	0,01	0,0031	0,051	0,0038	0,0041	0,0051	0,004	0,0031	13	392	321	458	288
828	678334	7201151	0,104	2,1	1,8	11,0	91,3	6,83	1,77	0,0301	-	0,0033	0,042	0,0043	0,0052	0,0044	-	12	448	381	565	330	
908	678264	7198741	0,601	2,1	2,1	8,8	80,84	16,82	2,07	0,0066	0,102	0,0018	0,11	0,0085	0,002	-	0,0066	0,0264	9	580	137	222	99
918	678342	7197414	0,078	2,1	2,2	10,2	89,74	8,62	1,49	0,0424	0,025	0,0024	0,05	0,0064	0,005	0,0043	0,0052	0,0072	11	542	290	459	229
1038	676754	7196237	0,685	2,1	2,0	10,8	80,07	18,07	1,31	0,0204	0,076	0,0017	0,08	0,011	0,0026	-	0,0147	0,028	11	549	158	251	125
1068	676001	7197429	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
1108	677669	7198244	0,010	2,1	1,9	9,6	83,29	15,51	0,98	0,0186	0,026	0,002	0,0652	0,0083	0,0018	-	0,0074	0,0063	7	461	165	247	124
1158	675686	7198561	0,023	2,0	2,3	9,3	92,56	5,89	1,41	0,0408	0,016	0,0033	0,047	0,0037	0,0035	0,0048	0,0042	0,0037	11	499	281	431	233
1208	675810	7197793	0,041	2,0	2,2	9,1	83,65	15,18	0,94	0,0055	0,061	-	0,075	0,012	0,0022	-	-	0,0048	10	526	156	245	121
1218	675701	7196767	1,010	2,0	2,2	10,0	84,43	14,54	0,85	0,0179	0,104	0,0017	0,037	0,0045	-	-	0,0038	0,0164	9	522	159	249	121
1228	675447	7196600	0,003	2,2	1,8	10,6	95,27	4,1	0,54	0,0197	0,052	-	0,006	0,0042	0,0048	-	13	378	295	417	267	188	
1258	674597	7195410	0,051	2,0	1,9	10,0	76,68	19,63	3,37	0,0471	0,043	0,0026	0,13	0,012	0,0032	-	0,0051	-	8	488	143	218	106
1298	674150	7196555	0,014	2,0	2,4	9,5	91,2	7,67	0,9	0,0318	0,062	0,0031	0,032	0,026	0,005	0,0049	0,0032	13	443	287	425	255	
1318	674620	7197223	0,034	2,1	1,8	8,9	89,5	9,12	1,2	0,0297	0,059	0,0018	0,041	0,0128	0,0045	-	0,0058	0,0069	11	478	264	400	219
1328	674927	7197615	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
1358	673299	7198585	0,062	2,2	2,1	11,0	91,22	7,91	0,79	0,026	0,011	0,0025	0,03	0,0025	0,0034	0,0051	0,003	-	11	385	294	417	257
1428	676315	7202531	0,090	2,2	2,5	9,7	91,38	7,08	1,39	0,0586	0,02	0,0041	0,042	0,0024	0,006	0,0055	0,0044	-	10	546	245	389	114
1688	671316	7198124	0,001	2,2	2,0	10,2	82,25	16,16	1,37	0,0427	0,07	0,0022	0,06	0,0037	0,0067	0,0049	0,0181	9	578	183	296	131	
1728	671748	7199616	0,068	2,0	1,7	89,28	8,63	1,92	0,0527	0,027	0,0032	0,06	0,0044	0,006	0,0045	0,0064	0,0066	11	532	244	383	195	
1848	672105	7200666	0,011	2,1	2,1	9,3	95,03	4,54	0,31	0,018	0,052	0,0018	0,02	0,0025	0,0077	0,0047	0,0091	0,0056	10	502	279	429	219
1888	671460	7195402	0,013	2,1	2,9	10,5	94,95	4,46	0,5	0,0088	0,05	-	0,035	-	0,0063	-	-	8	674	176	303	112	
1918	672361	7196693	0,009	2,3	2,2	10,5	92,13	6,72	0,99	0,0318	0,015	0,0025	0,079	0,0023	0,0024	0,0044	0,0026	-	11	302	274	366	245
1928	672505	7196004	0,007	2,1	2,4	9,9	94,94	4,49	0,46	0,0281	0,011	0,0019	0,026	0,0074	0,0105	0,0067	0,0048	-	13	364	395	552	362
1948	672268	7199123	0,809	2,0	1,9	10,9	80,62	17,79	1,29	0,0237	0,096	-	0,014	0,002	-	0,019	0,0218	8	600	153	252	104	
1968	671650	7198235	0,006	2,3	2,9	8,9	96,27	2,96	0,68	0,0297	-	0,0025	0,031	-	0,0057	0,0063	0,0059	-	14	348	397	549	370
1978	671817	7198564	0,921	2,0	2,8	9,6	85,36	13,46	0,88	0,0246	0,162	0,0017	0,082	0,0058	0,0019	-	0,0072	0,0176	11	454	139	208	118
1988	672262	7199855	0,131	2,0	2,4	10,7	93,1	5,67	1,1	0,0218	0,031	-	0,06	-	0,0037	-	0,0049	0,0073	10	656	236	400	169
1998	672340	7200177	0,018	2,1	1,5	11,0	98,38	1,5	0,108	0,0075	-	-	-	-	0,0019	-	0,0051	-	11	569	283	456	233
2028	672401	7202613	0,024	2,1	10,4	93,64	5,28	0,91	0,1262	0,027	0,0037	-	0,0662	0,0055	0,0038	-	10	444	278	411	227	158	
2038	672699	7202704	0,392	2,2	1,9	9,5	85,04	12,85	1,9	0,035	0,053	-	0,1	0,0035	0,003	-	0,006	0,0093	9	666	187	320	127
2088	670972	7202718	0,732	2,0	2,3	8,7	88,26	10,88	0,63	0,0142	0,107	-	0,068	0,0101	0,0015	-	0,0037	0,0261	10	511	124	192	99
2108	670510	7201951	1,000	2,0	2,8	8,9	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
2178	670698	7199911	0,020	2,2	2,4	12,0	96,65	3,06	0,24	0,0116	0,027	-	-	0,0067	-	0,0034	-	12	498	325	499	276	
2288	675657	7201341	0,463	2,0	2,5	10,1	87,7	10,71	1,46	0,0388	0,026	0,0026	0,05	0,0029	0,0049	-	0,0046	0,0048	10	665	157	269	112