



VICTOR ENMANUEL RODAS ARANO

**PREDIÇÃO DE COMPACTAÇÃO EM DOIS SOLOS SOB
DIFERENTES CONTEÚDOS DE ÁGUA COM SENSORES
PROXIMAIS**

LAVRAS – MG

2024

VICTOR ENMANUEL RODAS ARANO

**PREDIÇÃO DE COMPACTAÇÃO EM DOIS SOLOS SOB DIFERENTES
CONTEÚDOS DE ÁGUA COM SENSORES PROXIMAIS**

Dissertação apresentado à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Recursos Ambientais e Uso da Terra, para obtenção do título de Mestre

Prof. Dr. Bruno Montoani Silva
Orientador

Prof. Dr. Sergio Henrique Godinho Silva
Co-orientador

**LAVRAS – MG
2024**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a)

Rodas Arano, Victor Enmanuel.

Predição decompactação em dois solos sob diferentes
conteúdos de água com sensoresproximais / Victor Enmanuel
Rodas Arano. - 2024.

91 p. : il.

Orientador(a): Bruno Montoani Silva.

Coorientador(a): Sergio Henrique Godinho Silva.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2024.

Bibliografia.

1. Proximal sensors. 2. Soil compaction. 3. Machine learning. I.
Montoani Silva, Bruno. II. Godinho Silva, Sergio Henrique. III.
Título.

VICTOR ENMANUEL RODAS ARANO

**PREDIÇÃO DE COMPACTAÇÃO EM DOIS SOLOS SOB DIFERENTES
CONTEÚDOS DE ÁGUA COM SENSORES PROXIMAIS**

**PREDICTION OF COMPACTION IN TWO SOILS UNDER DIFFERENT WATER
CONTENTS WITH PROXIMAL SENSORS**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Recursos Ambientais e Uso da Terra, para obtenção do título de Mestre

Aprovada em 12 de Agosto de 2024

Dr. Bruno Montoani Silva	UFLA
Dr. Sérgio Henrique Godinho Silva	UFLA
Dra. Renata Andrade	UFLA
Dr. Milson Evaldo Serafim	IFMT

Prof. Dr. Bruno Montoani Silva
Orientador

Prof. Dr. Sergio Henrique Godinho Silva
Co-orientador

LAVRAS – MG

2024

Dedico este documento especialmente à minha família, minha mãe Deysi Virginia Arano Mejía, meu pai Jhonny Rodas Vargas, e minhas irmãs Carla e Pamela Rodas, pelo apoio em todas essas etapas de minha vida, pelos conselhos e ajuda, finalmente por serem parte de minhas inspirações e exemplos de vida.

Dedico

AGRADECIMENTOS

A Deus, por me dar a oportunidade e me conduzir pelos caminhos do conhecimento e do crescimento. A Jesus, por ter dado sua vida para que pudéssemos ser salvos. Ao Espírito Santo, que me ajudou e me guiou para estar seguro os novos caminhos da vida. Aos meus pais e minhas irmãs pelo grande apoio espiritual e financeiro para que eu pudesse estudar no estrangeiro e atingir meus objetivos e espero retribuir em algum momento de minha vida.

À prestigiosa Universidade Federal de Lavras, por abrir as portas para ampliar meus conhecimentos, especialmente ao Departamento de Ciência do Solo, que contribuiu para meu crescimento acadêmico e profissional. Agradeço ao apoio das instituições de fomento à pesquisa, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) Código de Financiamento 001, o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG), que foram fundamentais para o desenvolvimento desta pesquisa.

Agradeço o apoio do Professor Bruno Montoani Silva, por sua orientação, amizade, dedicação e paciência para me ajudar nessa etapa acadêmica da minha vida. Agradeço também ao meu coorientador Professor Sérgio Henrique Godinho Silva que não só me ajudou com a orientação, mas também pelas sugestões para o aperfeiçoamento da pesquisa, aos membros da banca e professores externos como a Professora Renata Andrade, Milson Serafim, Paulo Gherardi Hein pelo apoio nas sugestões e correções do documento.

Aos técnicos encarregados do Departamento de Física do Solo (Doroteo de Abreu, Maria Luiza de C. Andrade) e do Laboratório de Relação de Solo Planta (Mariene Helena Duarte e Geila Santos) pela ajuda na leitura com sensores e sugestões para melhorar a metodologia proposta em amostras indeformadas. Um agradecimento especial à Lara Mota Corinto pela ajuda e apoio durante todo esse processo, ao Jean Marcos Pereira dos Santos Reis pelo apoio no laboratório, os amigos do departamento Daiane, Samara, Josiel, Mateus, Gustavo, Sarah, Michel, Gilmar, Vanêssa, Hécio, Leandro, Eduane, Dione, Raul, Marcela, Larissa, Priscila, Carol, Tchu entre outros. Assim como meus amigos de outros departamentos, como Giovanni, Gean, Vivi, Ali, Roxana, Yhan, Diana, entre outros.

Pelo apoio na parte acadêmica e orientação dos procedimentos da universidade, como os professores Samara Martins, Betsy Muñoz, Eduardo Medeiros, John Jairo, Leônidas Canuto e meus amigos de língua espanhola e francesa, como Paul, Anyela, Javier, Francis, Alejandra, Nahum, Sara, Josselin, Altene, Jhonny, entre muitos outros.

Muito obrigado por sua amizade, do fundo do meu coração.

ABSTRACT

The prediction of adverse factors in agricultural production, such as excessive soil compaction, is crucial for taking preventive measures that reduce costs, drying time, environmental contamination, and sample destruction. In this study, undisturbed samples were collected from native vegetation (a transition between the Cerrado and Atlantic Forest in Lavras, Minas Gerais) from two soils (very clayey textured Latossolo Vermelho distroférico and clayey textured Latossolo Vermelho Amarelo distrófico) in PVC cylinders with an approximate diameter of 11.2 cm and height of 6.8 cm, at a depth of approximately 10 cm below the surface layer. After being subjected to a tension of 10 kPa, the samples were compacted using a modified uniaxial consolidometer to different degrees of compaction (70%, 80%, 90%) and a Proctor test for (100% and 110%). Once saturated, measurements were taken every two days with proximal sensors, including X-ray fluorescence (with chemical elements in percentages: Mg, Al, Si, P, K, Ca, Ti, V, Cr, Mn, Fe, Ni, Cu, Zn, As, Zr), electrical resistivity (ρ) with an X5xtal 250 (in Ω m), electrical conductivity (EC) with a Teros12 (in $\mu\text{S cm}^{-1}$), dielectric constant (K_a) with an ML2X (ϵ dimensionless), and volumetric water content (θ_v in $\text{m}^3 \text{m}^{-3}$), until the samples dried. A Random Forest algorithm was used to: (1) predict the degree of compaction through a regression model with data fusion from proximal sensors; (2) test the effect of excluding soil water content in predicting soil compaction with proximal sensors; (3) compare the potential of soil compaction prediction models generated by sensors of electrical properties (ρ , EC, K_a) with the pXRF sensor; and (4) predict soil compaction using Random Forest classification models. The regression model with Random Forest produced robust predictions. Despite having a smaller sample size ($n=4600$), LVdf showed better performance than LVAd ($n=4900$), achieving an $R^2=0.79$, RMSE=7.18, and MAE=4.66 based on external validation. When integrating both soils (LVdf+LVAd, $n=9500$), the model reached $R^2=0.93$. Although excluding water content (θ_v) did not significantly impact the accuracy of the models, it altered the importance of the variables, particularly Fe in LVdf and Si, Ti, Zn, and ρ in LVAd. When considering the sensors individually, the X-ray fluorescence (pXRF) sensor was better at predicting compaction compared to the electrical sensors, achieving an R^2 of 0.78 for LVdf and LVAd, finally $R^2=0.91$ when combining both soils. Although the accuracy metrics for the classification models were good, no clear pattern of variables based on the degree of compaction could be identified. However, it can be stated that certain variables lose their importance when compared between classification and regression models. The key variables identified were Si, Al, Cu, Fe, Ti, and EC.

Keywords: proximal sensors; soil compaction; machine learning; prediction models; soil electrical resistivity; soil dielectric constant; electrical conductivity; X-ray fluorescence.

RESUMO

A predição de fatores adversos na produção agrícola, como a compactação excessiva do solo, é crucial para tomar medidas preventivas que reduzem custos, tempo de secagem, contaminação ambiental e destruição de amostras. Neste estudo, foram coletadas amostras inalteradas de mata nativa (transição entre o Cerrado e Mata Atlântica em Lavras, Minas Gerais) de dois solos (Latosolo Vermelho distroférico de textura muito argilosa e Latossolo Vermelho Amarelo distrófico de textura argilosa) em cilindros de PVC com diâmetro aproximado de 11,2 cm e altura de 6,8 cm, a uma profundidade de aproximadamente 10 cm abaixo da camada superficial. Após serem submetidas a uma tensão de 10 kPa, as amostras foram compactadas usando um consolidômetro uniaxial modificado para diferentes graus de compactação (70%, 80%, 90%) e um ensaio Proctor para (100% e 110%). Uma vez saturado, as medições foram feitas a cada dois dias com sensores proximais, incluindo fluorescência de raios X (com elementos químicos em porcentagens: Mg, Al, Si, P, K, Ca, Ti, V, Cr, Mn, Fe, Ni, Cu, Zn, As, Zr), resistividade elétrica (ρ) com um X5xtal 250 (em Ω m), condutividade elétrica (CE) com um Teros12 (em $\mu\text{S cm}^{-1}$), constante dielétrica (Ka) com um ML2X (ϵ adimensional) e conteúdo de água volumétrico (θ_v em $\text{m}^3 \text{m}^{-3}$), até que as amostras secassem. Um algoritmo de Random Forest foi utilizado para: (1) prever o grau de compactação por meio de um modelo de regressão com fusão de dados de sensores proximais; (2) testar o efeito de excluir o conteúdo de água do solo na predição da compactação do solo com sensores proximais; (3) comparar o potencial dos modelos de predição de compactação do solo gerados por sensores de propriedades elétricas (ρ , CE, Ka) com o sensor pXRF; e (4) predições da compactação do solo usando modelos de classificação de Random Forest. O modelo de regressão com Random Forest gerou predições robustas. Apesar de ter um tamanho de amostra menor ($n=4600$), o LVdf mostrou um desempenho superior ao LVAd ($n=4900$), atingindo $R^2=0,79$, $\text{RMSE}=7,18$ e $\text{MAE}=4,66$ em base uma validação externa. Ao integrar ambos solos (LVdf+LVAd, $n=9500$), o modelo alcançou $R^2=0,93$. Embora a exclusão do conteúdo de água (θ_v) não impactou significativamente na precisão dos modelos, mas alterou a importância das variáveis, especialmente Fe no LVdf e Si, Ti, Zn e ρ no LVAd. Considerando os sensores individualmente, o sensor de fluorescência de raios X (pXRF) foi melhor na predição em comparação com os sensores elétricos, alcançando um $R^2=0,78$ para LVdf e LVAd, e $R^2=0,91$ ao combinar ambos os solos. Apesar de as métricas de precisão dos modelos de classificação serem boas, não foi possível identificar um padrão claro das variáveis com base no grau de compactação. No entanto, pode-se afirmar que certas variáveis perdem sua importância quando são comparadas entre os modelos de classificação e de regressão. As variáveis destacadas foram Si, Al, Cu, Fe, Ti e CE.

Palavras-chave: sensores proximais; compactação do solo; aprendizado de máquina; modelos de previsão; resistividade elétrica do solo; constante dielétrica do solo; condutividade elétrica; fluorescência de raios X.

INDICADORES DE IMPACTO

O presente estudo teve como objetivo analisar as interações e a influência das variáveis para poder prever na compactação do solo com o uso de algoritmos como Random Forest, revelando certas variáveis e resultados que podem impactar as tecnologias e metodologias de amostragem de solos, especialmente no âmbito de laboratório, proporcionando novas abordagens e perspectivas sobre o uso de sensores proximais e metodologias ambientalmente amigáveis. Com base nos resultados obtidos, foi identificado um potencial para o uso de novas metodologias e sensores para amostragem sem a alteração ou destruição de agregados, beneficiando o desenvolvimento de tecnologias e contribuindo com conhecimento para cientistas que buscam desvendar os fatores que influenciam a compactação do solo. O estudo obteve modelos robustos e precisos, obtendo resultados promissores com as variáveis Cu, Fe, Si, Ti, Al e condutividade elétrica. Podendo ajudar a compreender melhor o fenômeno da compactação do solo aos pesquisadores, docentes, estudantes e técnicos na área de estudo do solo. Dessa forma, promoveria a adoção de tecnologias futuras que podem impulsionar a automação e precisão no monitoramento de solos, permitindo uma intervenção precoce para a implementação de práticas de conservação e cuidado do solo, prevenindo futuras erosões. Essa otimização de recursos pode ter um impacto significativo na produção agrícola, beneficiando comunidades rurais que buscam homogeneização e controle na produção. Além disso, os resultados poderiam ser aplicados para a predição da densidade do solo em áreas relativamente grandes, utilizando modelos de pedotransferência, reduzindo o tempo de amostragem e os custos para projetos de gestão ambiental com foco em sustentabilidade e resiliência no cuidado e conservação dos solos. Finalmente, o projeto conseguiu alcançar principalmente quatro objetivos do desenvolvimento sustentável propostos pela ONU: 2) Fome zero e agricultura sustentável, podendo encontrar novas soluções para um melhor monitoramento dos solos agrícolas; 9) Indústria, inovação e infraestrutura, fortalecendo as pesquisas científicas com base em novos conhecimentos; 12) Consumo e produção sustentáveis, reduzindo o uso de resíduos químicos e conseguindo prevenir o surgimento de áreas erodidas, para aplicar estratégias de recuperação e a preservação da solo para a 15) Vida terrestre.

IMPACT INDICATORS

The present study aimed to analyze the interactions and influence of variables in predicting soil compaction using algorithms such as Random Forest, revealing certain variables and results that may impact soil sampling technologies and methodologies, especially in the laboratory context, providing new approaches and perspectives on the use of proximal sensors and environmentally friendly methodologies. Based on the results obtained, potential was identified for the use of new methodologies and sensors for sampling without altering or destroying aggregates, benefiting the development of technologies and contributing knowledge to scientists seeking to uncover the factors influencing soil compaction. The study produced robust and accurate models, yielding promising results with variables such as Cu, Fe, Si, Ti, Al, and electrical conductivity. These findings could help researchers, educators, students, and technicians in the field of soil studies to better understand the phenomenon of soil compaction. This, in turn, would promote the adoption of future technologies that could drive automation and precision in soil monitoring, allowing for early intervention to implement soil conservation and care practices, thus preventing future erosion. This resource optimization could have a significant impact on agricultural production, benefiting rural communities seeking homogeneity and control in production. Furthermore, the results could be applied to predict soil bulk density over relatively large areas using pedotransfer models, reducing sampling time and costs for environmental management projects focused on sustainability and resilience in soil care and conservation. Finally, the project successfully addressed four key Sustainable Development Goals proposed by the UN: 2) Zero hunger and sustainable agriculture, by finding new solutions for better agricultural soil monitoring; 9) Industry, innovation, and infrastructure, by strengthening scientific research based on new knowledge; 12) Sustainable consumption and production, by reducing chemical waste and preventing the emergence of eroded areas to apply recovery strategies and preserve soils for 15) Life on land.

LISTA DE ILUSTRAÇÕES

Figura 1 – Variação no tamanho dos componentes no solo	15
Figura 2 – Fluxograma do efeito da compactação do solo nas propriedades do solo e das plantas.....	17
Figura 3 – Corpo do sensor Teros 12/11 na vertical e agulhas na horizontal	31

LISTA DE TABELAS

Tabela 1 – Limites de diâmetros equivalentes das frações granulométricas definidas pelos sistemas de classificações de frações granulométricas de Classificação Norte Americano (USDA), Internacional (ISSS) e da Sociedade Brasileira de Ciência do solo (SBCS).....	16
Tabela 2 – Funções de pedotransferência consideradas em regiões tropicais	26

SUMÁRIO

FIRST PART	14
INTRODUÇÃO GERAL	14
1. REFERENCIAL TEÒRICO	15
COMPONENTES NO SOLO	15
TEXTURA E ESTRUTURA DO SOLO.....	16
COMPACTAÇÃO DO SOLO	17
O CONTEÚDO DE ÁGUA NO SOLO COMPACTADO	19
EFEITOS DA COMPACTAÇÃO NAS CULTURAS	19
AVALIAÇÃO DA COMPACTAÇÃO DO SOLO	20
TIPOS DE COMPACTAÇÃO DO SOLO.....	21
ENSAIO DE PROCTOR	21
COMPRESSÃO UNIAXIAL	22
PARÂMETROS NA COMPRESSIBILIDADE DO SOLO.....	23
PARÂMETROS QUANTITATIVOS PARA CARACTERIZAR A COMPACTAÇÃO DO SOLO	23
DENSIDADE DO SOLO	23
POROSIDADE E MACROPOROSIDADE	25
GRAU DE COMPACTAÇÃO.....	26
FUNÇÕES DE MODELOS DE PEDOTRANSFERÊNCIA	26
SENSOR DE CONSTANTE ELÉTRICA (THETAPROBE ML2X).....	28
SENSOR DE RESISTIVIDADE ELÉTRICA (X5XTAL 250).....	30
SENSOR DE CONDUTIVIDADE ELÉTRICA (TEROS 12).....	30
SENSOR DE FLUORESCÊNCIA POR RAIOS X	32
ALGORITMO DE RANDOM FOREST	33
PREDIÇÃO DA DS COM SENSORES PROXIMAIS	34
REFERÊNCIAS	37
SECOND PART – PAPERS	48
PAPER 1 - PROXIMAL SENSORS FUSION AND MACHINE LEARNING ALGORITHM COMBINED TO IMPROVE SOIL COMPACTION PREDICTION ...	49
1. INTRODUCTION	53
2. MATERIAL AND METHODS	55

2.1. SOIL SAMPLING AND PREPARATION	55
2.2. X5XTAL 250 SENSOR ANALYSES	57
2.3. TEROs 12 SENSOR ANALYSES	58
2.4. THETAPROBE ML2X SENSOR ANALYSES	59
2.5. PXRF SENSOR ANALYSES	59
2.6. DATA ANALYSES AND MODELING.....	60
2.7. EVALUATING MODELS PERFORMANCE.....	62
3. RESULTS AND DISCUSSION.....	63
3.1. CHARACTERIZATION OF VARIABLES AND PRINCIPAL COMPONENT ANALYSIS	63
3.2. REGRESSION MODELS WITH RANDOM FOREST	69
3.3. CLASSIFICATION MODELS WITH RANDOM FOREST.....	73
4. CONCLUSIONS.....	79
5. RECOMMENDATIONS	80
6. ACKNOWLEDGMENTS.....	80
7. REFERENCES	80
8. APPENDIX A – SUPPLEMENTARY MATERIAL.....	89
CONSIDERAÇÕES FINAIS.....	91

FIRST PART

INTRODUÇÃO GERAL

Um dos principais problemas na produção agrícola atual é a redução da quantidade dos macroporos (Hillel, 1982), causada tanto por fatores intrínsecos ou pedogenéticos, como o adensamento do solo (Cardoso *et al.*, 2004) devido à obstrução dos poros por material coloidal e mineral (partículas de silte) nas camadas inferiores. Por outro lado, os fatores externos são em sua maioria antrópicos, como a má gestão agrícola aplicando forças na superfície, gerando compactação, seja pelo sobrepastoreio ou pelo tráfego de máquinas em condições inadequadas de umidade do solo, afetando a fisiologia das culturas (Dias Junior, 2000; Richart *et al.*, 2009; Soane e Ouwerkerk, Van, 1994).

A compactação, ao modificar a disposição espacial dos constituintes do solo e reduzir significativamente seu volume de poros, aumentará a densidade aparente (Keller *et al.*, 2017). Por isso, a densidade aparente pode ser um bom parâmetro para caracterizar a compactação do solo (Reis *et al.*, 2024; Vos, De *et al.*, 2005), proporcionando valores diretamente comparáveis para solos com teor de argila entre 2 até 60% (Håkansson e Lipiec, 2000). No entanto, pode apresentar problemas temporais, pois não considera o movimento do ar e da água ao longo do tempo, sendo recomendável avaliar as amostras com um conteúdo de água uniforme.

Além disso, considerando as variáveis mais importantes e as relações empíricas dos modelos matemáticos de pedotransferência, é possível estimar as propriedades do solo com base em informações prévias, sem a necessidade de amostragem em campo, economizando custos, trabalho e tempo (Abdelbaki, 2018; Kaur, Kumar e Gurung, 2002; Nasta *et al.*, 2020; Reis *et al.*, 2024). Entre os modelos aplicados para solos brasileiros, os disponíveis são um pouco mais limitados (Benites *et al.*, 2007; Bernoux *et al.*, 1998; Tomasella e Hodnett, 1998)

A maioria dos modelos de pedotransferência considera variáveis mais representativas, como análises texturais (especialmente argila e areia) e conteúdo de carbono orgânico com diferentes teores de água, devido aos elevados custos das análises químicas (Heuscher, Brandt e Jardine, 2005; Manrique e Jones, 1991; Vos, De *et al.*, 2005). No entanto, ao substituir argila e carbono orgânico por conteúdo de areia, capacidade de troca catiônica e teor de óxido de Fe, foi possível aumentar o R^2 e diminuir o SE, mas a quantidade de dados é limitada pelo elevado custo (Bernoux *et al.*, 1998).

Com o desenvolvimento das tecnologias de sensores proximais e sua maior acessibilidade é possível acrescentar a base de dados e melhorar os modelos de predição dos atributos do solo, como a densidade aparente (D_s), sem destruir ou alterar sua estrutura. Entre os sensores disponíveis, destacam-se aqueles que medem resistividade elétrica (Kowalczyk,

Maślakowski e Tucholka, 2014; Lueck e Ruehlmann, 2013; Melo *et al.*, 2021a; Seladji *et al.*, 2010), condutividade térmica com θ_v (Tian *et al.*, 2020), espectroscopia no infravermelho próximo Vis-NIR com FDR (Al-Asadi e Mouazen, 2014a), condutividade elétrica com susceptibilidade magnética (Pentos, Pieczarka e Serwata, 2021), e penetrômetros com vis-NIR (Quraishi e Mouazen, 2013). Inclusive experimentos têm usado esses sensores para prever outros atributos do solo, como textura (Andrade *et al.*, 2022; Benedet *et al.*, 2020; Naderi-Boldaji *et al.*, 2019); conteúdo de matéria orgânica ou carbono (Faria *et al.*, 2022; Raesi *et al.*, 2019; Viscarra Rossel, McBratney e Minasny, 2010); classificação da cor do solo (Mancini *et al.*, 2020); fertilidade do solo (Teixeira *et al.*, 2022a); contaminação do solo (Vingiani *et al.*, 2024); e conteúdo de água (Alaoui e Helbling, 2006; Pahuja, 2022), que pode influenciar na compactação do solo.

No caso do pXRF e do condutímetro é importante considerar que o conteúdo de água no momento da análise pode subestimar os elementos químicos (Silva *et al.*, 2018) devido à sua capacidade de absorver a energia dos raios X primários (Stockmann, Uta *et al.*, 2016), embora a umidade possa ajudar na condução de energia elétrica (Mouazen e Al-Asadi, 2018).

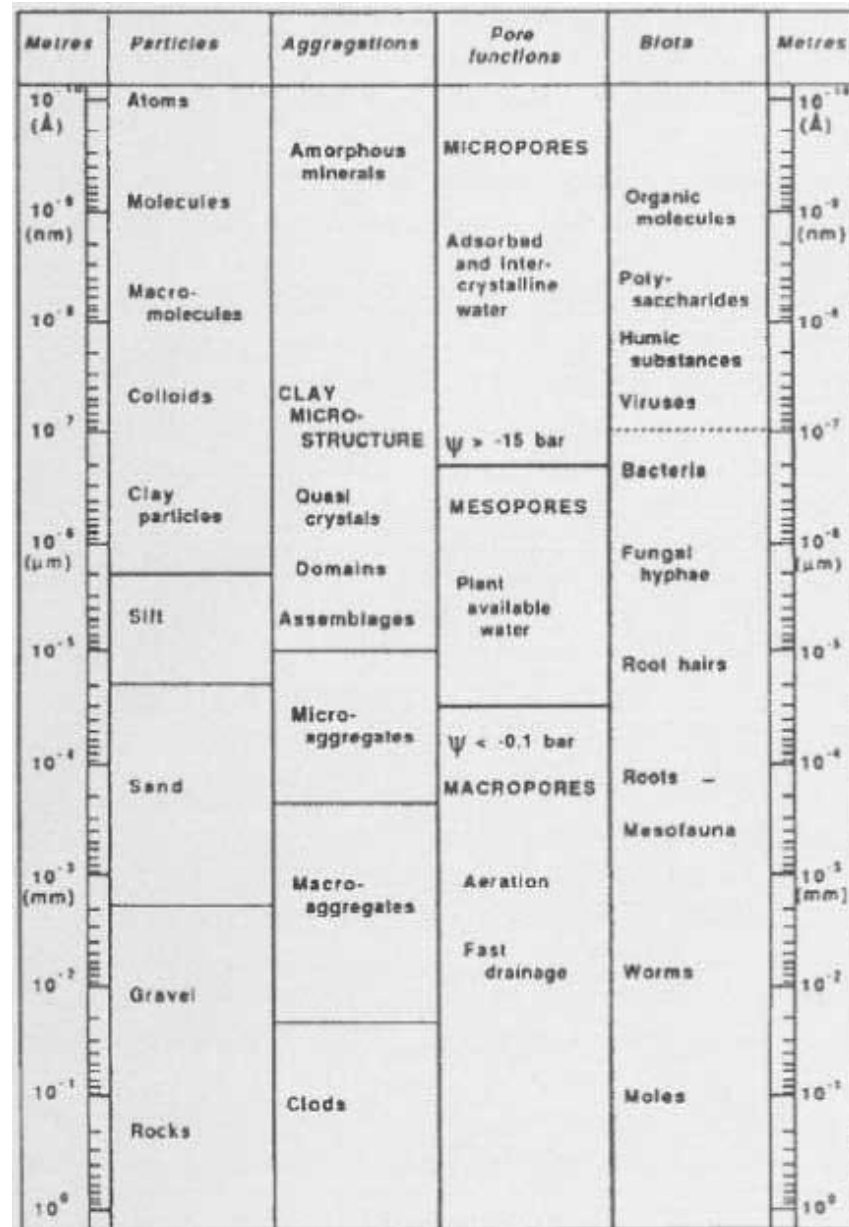
Considerando toda essa informação, tem-se a hipótese de que é possível obter modelos de predição precisos para o grau de compactação combinando sensores proximais e o algoritmo Random Forest. Com os objetivos de: (1) prever o grau de compactação utilizando um modelo de regressão e a fusão de dados de sensores proximais (pXRF, ML2x, X5xtal 250, TEROS12); (2) verificar o efeito da inclusão ou não do teor de água do solo na previsão da compactação do solo com sensores proximais; (3) comparar o potencial dos modelos de predição da compactação do solo gerados utilizando sensores de propriedades elétricas (ρ , CE, K_a) com o sensor pXRF; e (4) prever a classificação da compactação do solo utilizando o modelo de classificação do algoritmo Random Forest.

1. REFERENCIAL TEÓRICO

Componentes no solo

O solo do ponto de vista da Física do Solo é considerado um sistema trifásico heterogêneo. Composta principalmente de três fases: a fase sólida que constitui a matriz do solo (componentes sólidos minerais e orgânicos); a fase líquida na qual existem substâncias dissolvidas (solução do solo); e a fase gasosa que é atmosfera do solo (Jong Van Lier, De, 2010). Tanto o ar e água do solo pode variar em composição tanto no tempo como no espaço.

Figura 1. Variação no tamanho dos componentes no solo (Horn e Lebert, 1994) *apud* (Kay, 1990)



Fonte: Kay (1990)

A parte mineral do solo é resultado do intemperismo do material de origem, apresentando diversas formas, tamanho, arranjos e composições (Ferreira *et al.*, 2003; Hillel, 1982).

Textura e estrutura do solo

A textura do solo é uma das características físicas que representa a distribuição quantitativa das partículas sólidas minerais menores que 2 mm em diâmetro (Jong Van Lier, De, 2010). Independentemente do sistema de classificação, as três frações texturais do solo (Areia, Silte, Argila) apresentam diferentes diâmetros.

Tabela 1. Limites de diâmetros equivalentes das frações granulométricas definidas pelos sistemas de classificações de frações granulométricas de Classificação Norte Americano (USDA), Internacional (ISSS) e da Sociedade Brasileira de Ciência do solo (SBCS)

Frações	Sistemas		
	USDA Ø (mm)	ISSS Ø (mm)	SBCS Ø (mm)
Areia muito grossa	2 – 1	-	-
Areia grossa	1 – 0,5	2 – 0,2	2 – 0,2
Areia média	0,5 – 0,25	-	-
Areia fina	0,25 – 0,10	0,2 – 0,02	0,2 – 0,05
Areia muito fina	0,10 – 0,05	-	-
Silte	0,05 – 0,002	0,02 – 0,002	0,05 – 0,002
Argila	< 0,002	< 0,002	< 0,002

Fonte: Adaptado de Jong Van Lier (2010)

Dentro dos fatores internos que influenciam a compactação do solo são: textura, estrutura, ciclos de secagem e umedecimento e densidade do solo (Lima *et al.*, 2004).

Além dos outros fatores a estrutura do solo também influencia a compactação do solo, já que representa a organização das partículas sólidas do solo e os espaços porosos entre elas (Hillel, 1982). Do ponto de vista físico a estrutura do solo refere-se ao arranjo e disposição das partículas que compõem a massa de terra na formação de um sistema poroso do solo (Jong Van Lier, De, 2010).

Compactação do solo

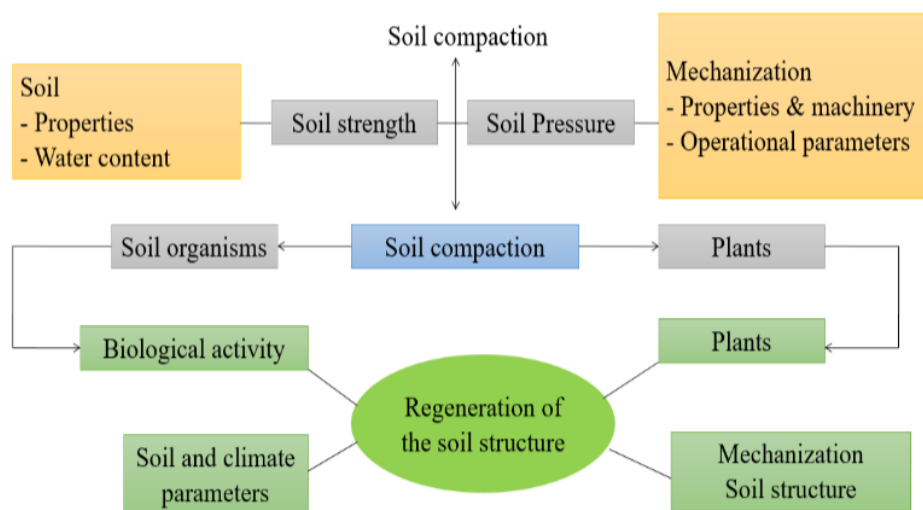
A compactação do solo é definida como: "o processo pelo qual os grãos do solo se reorganizam para diminuir o espaço vazio e aproximá-los uns dos outros, aumentando assim a densidade aparente" (Soil Science Society of America, 1997). Esse processo afeta os agregados do solo ao alterar a disposição, o tamanho e a forma dos torrões e agregados, assim como os espaços porosos entre eles. (Defossez e Richard, 2002; Hamza e Anderson, 2005).

A compactação é um dos tipos de degradação mais difíceis de identificar e entender, principalmente porque pode não apresentar sinais visíveis na superfície do solo a diferença da erosão e da salinização que mostram evidências claras na superfície (Hamza e Anderson, 2005). De acordo a (Ferreira *et al.*, 2003), dentre os sintomas observados nos solos excessivamente compactados, pode destacar: as presença de costras, aparecimento de trincas, zonas endurecidas baixo da superfície do solo, empoçamento de água, erosão pluvial excessiva, presença de resíduos vegetais parcialmente descompostos, necessidade de maior potência das máquinas de

cultivo, baixa emergência das plantas, variação no tamanho das plantas, folhas amareladas, sistema radicular pouco profundo e malformadas com crescimento deficiente das culturas (Bengough, Mckenzie, *et al.*, 2011; Lipiec *et al.*, 2012; Szatanik-Kloc *et al.*, 2018), afeta o carbono orgânico do solo e a mineralização do nitrogênio (Neve, De e Hofman, 2000), bem como a concentração de dióxido de carbono no solo (Conlin e Driessche, den, 2000).

Os processos de redução do volume dos poros e de aumento da densidade do solo podem ser devidos a fatores pedogenéticos, como o adensamento do solo devido ao entupimento dos poros por material coloidal orgânico e mineral (Cardoso *et al.*, 2004) das camadas verticais do solo ao longo do tempo (Biz, Andrade e Silva, 2022) e processos antropogênicos causados por forças externas aplicadas na superfície, geralmente associado à agricultura intensiva que têm um impacto degradante maior (Defosse e Richard, 2002; González Cueto, Iglesias Coronel e Herrera Suárez, 2009; Richart *et al.*, 2009).

Figura 2. Fluxograma do efeito da compactação do solo nas propriedades do solo e das plantas (Patel *et al.*, 2021)



Fonte: Patel et al., (2021)

Outros autores (Giarola e Silva, 2002), descrevem ao adensamento como solos coesos ou *hardsetting soils*. Quando, apresentam um incremento acentuado de resistência à penetração em estado seco, e uma sensível redução dessa resistência quando ficam úmidos.

Um dos fatores mais importantes na suscetibilidade da compactação do solo é o teor de água do solo (Dias Junior, 2000; Soane e Ouwerkerk, Van, 1994), também é fortemente influenciada pela estrutura do solo, que representa a organização das partículas sólidas do solo e os espaços porosos entre elas (Hillel, 1982). Por exemplo, os solos com estrutura em blocos apresentam maior resistência à compactação em comparação com os solos com estrutura granular (Ajayi *et al.*, 2009).

Na América Latina e no Caribe (LAC), a produção de pecuária e o tráfego de máquinas são as principais causas da compactação do solo e inclusive pode reduzir em até 60% os rendimentos mundiais das culturas agrícolas. (FAO & ITPS, 2015) De acordo com (Mc Garry e Sharp, 2003) os agricultores raramente relacionam suas práticas de manejo do solo com as causas da degradação estrutural do solo e muitos continuam com práticas de lavoura profunda. Dado que a compactação do subsolo é persistente e as tentativas de afrouxamento natural ou artificial têm sido decepcionantes, a União Europeia (UE) reconheceu como uma forma grave de degradação do solo (Akker e Canarache, 2001)

O conteúdo de água no solo compactado

O conteúdo de água promove as alterações na consistência dos solos, grau de mudança da consistência, magnitude de deformação no solo, resistência ao preparo, capacidade de suporte de carga e na resistência de compressão (Jong Van Lier, De, 2010; Larson *et al.*, 1994). Essa preocupação é crucial nos estudos atuais que buscam desenvolver modelos para expressar a sustentabilidade dos sistemas de uso e manejo dos solos, considerando uma caracterização mais completa do solo. (Jong Van Lier, De, 2010).

Efeitos da compactação nas culturas

Independente da cultura, a compactação do solo pode ter efeitos benéficos, atribuídos à melhoria do contato solo-semente (Smucker e Erickson, 1989) e ao aumento da disponibilidade de água em anos secos (Raghavan e McKyes, 1983). Os efeitos da compactação excessiva nas culturas afetam principalmente na porosidade do solo, sobretudo, na macroporosidade influenciando na infiltração e a rápida redistribuição da água e aeração no solo ou troca de gases (limite da porosidade de aeração não menor 10%) (Jong Van Lier, De, 2010; Smucker e Erickson, 1989; Stone, Guimarães e Moreira, 2002). Também afeta no desenvolvimento das raízes ao não ter o turgor suficiente para mover as partículas, conseqüentemente, ocorre uma deposição de microfibras de celulose longitudinais nas paredes das células primárias do córtex das raízes, inibindo o crescimento axial e promovendo o crescimento lateral das camadas (Nelson Beutler *et al.*, 2006; Veen, 1982). Também, evidenciou-se que a compactação do solo pode induzir alterações na absorção e concentração de nutrientes nas plantas. (Juang e Uehara, 1972) verifica-se uma redução na concentração de fósforo à medida que aumentou a compactação na cana de açúcar. Já (Corrêa *et al.*, 2001), estudando o efeito da compactação em diferentes classes de solos, verificaram aumento nos teores de S, K, N e redução de Zn, B, Fe, Ca e Mg na cana-de-açúcar, à medida que aumentou a compactação (Alves *et al.*, 2003).

Avaliação da compactação do solo

A avaliação da compactação do solo está relacionada a altos valores de densidade do solo e baixa porosidade total, além de maior dificuldade de penetração radicular (RP), até os mesmos implementos agrícolas (Reichardt e Timm, 2014).

É possível avaliar a compactação de um solo de forma qualitativa ou semiquantitativa com a Avaliação Visual da Estrutura do Solo (VESS) proposta por (Guimarães Es, Ball e Tormena, 2011). Outros indicadores incluem o método do "perfil cultural", que é o mais utilizado (Gautronneau e Manichon, 1987; Richard *et al.*, 1999), embora requeira conhecimentos específicos, tempo e esforço consideráveis. Existem métodos que exigem menos tempo e esforço, como as provas de pá. Também, unindo ou modificando certos métodos, observou-se uma melhora na avaliação da estrutura (VSSQA) desenvolvida por (Ball, Batey e Munkholm, 2007) baseando-se no teste de Peerlkamp (Peerlkamp, 1959), podendo ser uma prova compreensível, objetiva e rápida, correlacionando-se com os rendimentos das culturas. No entanto, há certa subjetividade por parte de operadores inexperientes (Giarola *et al.*, 2009). A porosidade visível a olho nu (porosidade visível-VP) dentro dos agregados pode ser utilizada como critério adicional para avaliar a estrutura (Roger-Estrade *et al.*, 2004). No entanto, a densidade do solo é a propriedade mais destacada nessas comparações (Johannes *et al.*, 2017). Junto com análises visuais, a densidade do solo tem ajudado a interpretar de forma mais ampla os problemas no campo e a compreender as influências do manejo do solo na sua estrutura, especialmente na infiltração de água, erosão e no desenvolvimento das raízes das plantas (Pulido Moncada *et al.*, 2014)

Todas essas metodologias precisam ser avaliadas detalhadamente, por exemplo, (Ball *et al.*, 2015) observou que a SubVESS dá mais prioridade à estrutura do que à textura, impedindo o reconhecimento de efeitos como a baixa capacidade de retenção de água.

Um dos métodos mais usados para diagnosticar a compactação do solo é a medição da resistência à penetração (RP) com um penetrômetro de cone, pois simula a resistência do solo à penetração das raízes (Hamza e Anderson, 2005; Mome Filho *et al.*, 2014; Panayiotopoulos, Papadopoulou e Hatjioannidou, 1994; Peixoto *et al.*, 2019), considerando os valores críticos de macroporosidade ($0,10 \text{ m}^3 \text{ m}^{-3}$) e resistência à penetração (2 MPa) (Mome Filho *et al.*, 2014; Taylor, Roberson e Parker Jr, 1966). Este método é simples, rápido, fácil de aplicar no campo e de baixo custo (Blake e Hartge, 1986). No entanto, a RP é fortemente influenciada pelo conteúdo de água no solo (Hamza e Anderson, 2005; Vaz *et al.*, 2011).

A taxa de infiltração de água no solo pode ser usada para monitorar o estado de compactação, especialmente na camada superficial. A água infiltra-se mais rapidamente em

solos não compactados com partículas bem agregadas do que em solos maciços e sem estrutura (Cueto, Coronel e Suárez, 2009; Hamza e Anderson, 2005).

Outra forma de avaliar é a distribuição de poros por tamanho, especialmente nos macroporos (Dias Junior e Pierce, 1996; Ribeiro *et al.*, 2007). Tomando mostras indeformadas com anéis de 100 cm³ para depois ser saturadas e levadas a pressão ou sucção de (-0,006 MPa) sendo em base ao volume e o peso seco para poder calcular a porosidade, esta metodologia leva tempo a conta de que precisa ser saturado para depois ser secado em estufa (Dias Junior e Pierce, 1996; Suzuki *et al.*, 2007; Tormena *et al.*, 2002).

Tipos de compactação do solo

De acordo com (Radzi *et al.*, 2019) há quatro tipos de esforço de compactação no solo ou no asfalto: a) Vibração; b) Impacto; c) Amassamento; d) Pressão.

Ensaio de proctor

Graças aos testes (Proctor, 1933), foi desenvolvida uma compactação dinâmica, que consiste em colocar o solo em um molde e deixar cair um compactador ou martelo sobre o solo um determinado número de vezes.

Posteriormente, foi aperfeiçoado e padronizado pela ASTM (D-648) e pela AASHTO (T-99), a fim de determinar a relação entre o teor de água (umidade) e o peso específico seco dos solos. O Teste Proctor Padrão foi criado para representar em laboratório os resultados que poderiam ser obtidos com o equipamento comumente usados na década de 1930 para compactação do solo no campo (Armas Novoa e González Haramboure, 2008).

Com o desenvolvimento dos equipamentos de compactação, tornou-se necessário obter pesos secos específicos no campo, maiores do que os obtidos no Standard Proctor Test, na construção de rodovias, aeroportos e barragens de terra (Evans, Ruffing e Elton, 2021). Por isso, foi criado o Ensaio Proctor Modificado, baseado no mesmo princípio, variando o peso e a altura do martelo (Armas Novoa e González Haramboure, 2008). Esse teste foi aperfeiçoado e padronizado pela ASTM (D-1557) e pela AASHTO (T-180).

Quanto à energia de compactação empregada de acordo a norma técnica NBR 7182/16 (ABNT, 2016) reconhece três intensidades de compactação: normal, intermediária e modificada. Detalhes inerentes a cada energia de compactação podem ser obtidos na referida norma (Dias Junior *et al.*, 2024).

No estudo da compactação do solo em ciências agrárias, o ensaio de Proctor normal (NBR, 2016), proposto por Ralph R. Proctor, em 1933, tem sido amplamente o mais empregado (Dias Junior *et al.*, 2024). Entretanto (Ramos *et al.*, 2013), concluem que o procedimento de reuso da amostra de solo aumenta a densidade do solo máxima de compactação pela

fragmentação dos agregados e reorganização das partículas. O preparo da amostra de solo deve ser feito, de acordo com a norma técnica NBR 6457/86 (NBR, 2016), empregando-se material seco que passe em peneira de malha de 4,8 mm. O ensaio de Proctor normal consiste basicamente em compactar um corpo de prova, constituído de três camadas, em um cilindro (pequeno) com volume de $1000 + 10 \text{ cm}^3$. Para tanto, emprega-se um soquete (pequeno) de massa ($2.500 \pm 10 \text{ g}$) e dotado de dispositivo de controle de altura de queda ($305 \pm 2 \text{ mm}$) (Días Junior *et al.*, 2024). Cada camada recebe 26 golpes desse soquete (ABNT, 2016), correspondendo a uma energia de compactação de aproximadamente 6 kgf cm cm^{-3} .

Esse aumento da densidade do solo máxima segue a mesma tendência da fração de areia (Días Junior *et al.*, 2024) e pode ser por maior capacidade de rearranjo das partículas do solo em razão da forma irregular dos grãos de areia (OHU).

Apesar de o ensaio de Proctor normal é relativamente simples, acredita-se que ele seja limitado ao estudo da compactação de solos agrícolas, considerando a necessidade de destruir a estrutura do solo ou que apagara o histórico de manejo de solo (Días Junior *et al.*, 2024).

Compressão uniaxial

Um dos ensaios de laboratório para o diagnóstico da compactação do solo mais utilizados na investigação, além do ensaio de Proctor normal é o ensaio de compressão uniaxial (Días Junior *et al.*, 2024).

O ensaio de compressão uniaxial consiste basicamente em aplicar uma sucessão de pressões que são realizadas com equipamentos denominados consolidômetros, mantidas a sob pressões sequenciais constantes já pré-estabelecidas (25, 50, 100, 200, 400, 800 e 1600 kPa) e sem descompressão a uma amostra de material de solo confinado lateralmente em condição não saturada (Dias Junior e Martins, 2017; Giarola e Silva, 2002; Schjønning *et al.*, 2016). Assim são obtidas as curvas de compressão do solo, que permitem quantificar as reduções de volume do solo e, portanto, pode ser usada para determinar a densidade do solo máxima que é necessária para o cálculo do grau de compactação (Reichert *et al.*, 2009; Tassinari *et al.*, 2021). Quando o solo não sofreu nenhuma pressão prévia, essa relação é linear, e a aplicação de qualquer pressão resultará em deformações não recuperáveis, causando, assim, compactação do solo.

A compressão uniaxial (Dias Junior e Martins, 2017) tem os mesmos princípios do ensaio de adensamento unidimensional. A diferença do ensaio de compressão uniaxial com o ensaio de adensamento, é que de compressão uniaxial é realizado com amostras de solo não saturadas.

A compressibilidade do solo é fortemente afetada pelas condições iniciais do solo, como a densidade aparente e o potencial hídrico (Imhoff *et al.*, 2016; Lima, de *et al.*, 2018; Reichert *et al.*, 2018).

A pressão de pré-consolidação depende de vários fatores, tais como: mudanças na tensão total a que o solo se encontra submetido pela erosão e escavações; processos de secagem e umedecimento; textura e mineralogia; estrutura e densidade do solo; uso e manejo do solo; teor e características da matéria orgânica do solo; condições iniciais do solo; alterações químicas do solo pelo intemperismo; precipitações pluviométricas; agentes cimentantes; pH; troca de ions, dentre outros (Ajayi *et al.*, 2009; Dias Junior e Martins, 2017; Dias Junior e Miranda, 2000; Reichert *et al.*, 2018; Suzuki *et al.*, 2007).

Parâmetros na compressibilidade do solo

A compressibilidade do solo está em função dos fatores externos e internos (Lebert e Horn, 1991). Dentro dos fatores externos temos o tipo, intensidade e frequência da carga aplicada (Horn e Lebert, 1994; Lebert e Horn, 1991; Raghavan, Alvo e McKyes, 1990), embora os fatores internos são influenciados pela história de tensão (Dias Júnior, 1994; Dias Junior e Estanislau, 1999; Reinert, 1992), umidade do solo (Dias Júnior, 1994), textura do solo (Gupta e Allmaras, 1987; McBride, 1989), estrutura do solo (Dexter e Tanner, 1974; Horn, 1988), e densidade inicial do solo (Culley e Larson, 1987; Gupta, 1984; Reinert, 1992)

Para uma mesma condição, o fator que governa a quantidade de deformação que poderá ocorrer no solo é a umidade (Dias Júnior, 1994). Assim, quando os solos estão mais secos, a sua capacidade de suporte de carga pode ser suficiente para suportar as pressões aplicadas e a compactação do solo pode não ser significativa (Dias Júnior, 1994; Kondo e Dias Junior, 1999; Larson e Allmaras, 1971). Entretanto, qualquer compactação é detrimental para as plantas sob condições de alta umidade (Swan, 1987), o que pode causar redução na produção (Bicki e Siemens, 1991; Carter, 1985; Gameda *et al.*, 1985; Negi *et al.*, 1980). Em áreas que possuem uma pequena estação de crescimento de plantas, as operações de preparo do solo são realizadas assim que os solos são considerados trafegáveis, entretanto, sob estas condições os solos provavelmente ainda estão muito úmidos para serem trafegados (Håkansson, Voorhees e Riley, 1988) e este tráfego frequentemente resultará em deformações não recuperáveis (compactação do solo).

Parâmetros quantitativos para caracterizar a compactação do solo

Densidade do solo

De acordo com (Hamza e Anderson, 2005) a densidade aparente relativa ou densidade do solo pode ser um bom parâmetro para caracterizar a compactação de um solo,

proporcionando valores diretamente comparáveis para todos os solos (Håkansson e Lipiec, 2000).

A densidade do solo (ρ , kg m⁻³) ou densidade aparente é um atributo dinâmico, que representa a relação entre a massa do solo seco em estufa (m_{ss} , kg) e seu respectivo volume total (V , m³). Sendo o volume do solo incluindo os espaços ocupados pela água (V_a) e pelo ar (V_{ar}) (Jong Van Lier, De, 2010). Pode estar expressa pela seguinte equação:

$$\rho = \frac{m_{ss}}{V} \quad \text{Eq. (1)}$$

Devido à relação entre a densidade do solo e sua compactação com a capacidade de armazenar e transportar água, a densidade aparente do solo é o parâmetro mais utilizado para caracterizar o estado de compactação no solo (Hamza e Anderson, 2005; Jong Van Lier, De, 2010; Panayiotopoulos, Papadopoulou e Hatjioannidou, 1994). No entanto, em solos inchados/contraídos, a densidade aparente deve ser determinada com teores de umidade padronizados, para evitar problemas causados por variações no teor de água (Hamza e Anderson, 2005; Panayiotopoulos, Papadopoulou e Hatjioannidou, 1994).

A densidade do solo conseguiu explicar as características do sistema poroso no solo, no entanto não toma em conta a disposição das partículas do solo que pode refletir diretamente em ρ , ou seja, é dependente da estrutura, composição mineralógica da fração argila do solo e teor de matéria orgânica em todos seus aspectos (Jong Van Lier, De, 2010). Assim, explica-se a grande variação da densidade do solo em Latossolos brasileiros no B_w de ρ entre 900 a 1550 kg m⁻³. Igualmente os valores mais baixos de ρ estão associados ao solo com estrutura granular e os mais elevados com estrutura tipo em blocos, dando um ênfase em estudar a diferenciação de camadas adensadas e camadas compactadas (Grohmann, 1975; Jong Van Lier, De, 2010).

Os métodos para a determinação da ρ são agrupados em métodos destrutivos e não destrutivos, tendo a menor perturbação e refletindo a condição mais próxima possível da sua condição natural (Jong Van Lier, De, 2010). Dentro dos destrutivos temos dois métodos que são os mais utilizados para representar de forma geral: O primeiro denominado o método de anel volumétrico (cilindro de Uhland), no qual um cilindro de volume conhecido é introduzido em uma camada, em seguida, o excesso de solo é cortado nas extremidades e depois secado em uma estufa a 105-110 °C por 48 horas (Reichardt e Timm, 2014); O segundo é o método do torrão impermeabilizado que tem certa dificuldade em determinar o volume de torrão que fica revestida em parafina, para o posterior cálculo da massa de água deslocada mediante o princípio de Arquimedes. É importante é definir o tamanho da amostra adequadamente em relação a espessura da camada a ser analisada (Jong Van Lier, De, 2010).

Os métodos não destrutivos são aqueles cuja determinação de ρ não precisa da retirada de amostras, mas por serem indiretos, exigem calibração prévia para cada tipo de solo (Jong Van Lier, De, 2010). Dentre essas técnicas, destacam-se a interação de um feixe de radiação gama com fonte de ^{60}Co , ^{137}Cs e ^{241}Am , sendo o número radiações espalhadas (pelo efeito de Compton) a atinge o detector proporcionalmente ao ρ (Reichardt e Timm, 2014); outra opção para determinar a ρ pode ser mediante a atenuação ou moderação de nêutrons com sondas gama-nêutron de nas camadas superficiais que pode detectar até 30 cm de profundidade e inclusive em camadas compactadas (Tominaga *et al.*, 2000). E inclusive avalio a estrutura da variabilidade espacial e temporal de dados de densidade do solo e umidade ao longo de um cafezal (Timm *et al.*, 2006).

Porosidade e Macroporosidade

A porosidade total constitui-se numa caracterização parcial do sistema poroso, podendo ser realizado em base a densidade do solo e da partícula.

Da equação da densidade do solo

$$V = \frac{m_s}{\rho} \quad \text{Eq. (2)}$$

Do mesmo modo de densidade de partícula

$$V_s = \frac{m_s}{\rho_s} \quad \text{Eq. (3)}$$

A divisão da equação resulta em

$$\frac{V_s}{V} = \frac{\rho}{\rho_s} \quad \text{Eq. (4)}$$

Sendo a porosidade total como a fração do solo em volume não ocupada por sólidos

$$\alpha = \left(1 - \frac{V_s}{V}\right) = \left(1 - \frac{\rho}{\rho_s}\right) \quad \text{Eq. (5)}$$

Os valores de porosidade total estimam-se entre 0,3 e 0,70 $\text{m}^3 \text{m}^{-3}$, sendo influenciados pela estrutura, textura e matéria orgânica no solo. Sendo responsáveis pela retenção e armazenamento de água os microporos, ao passo que os macroporos são responsáveis pela infiltração e redistribuição do ar. Sendo os valores limítrofes de diâmetro entre 30 μm (0,03 mm) a 100 μm (0,10 mm) (Jong Van Lier, De, 2010).

A Macroporosidade é também utilizada para estudos de grão de compactação do solo (Reichardt e Timm, 2014). Valores baixos de macroporosidade podem resultar em baixa aeração, má drenagem, e aumento de resistência de penetração (Håkansson e Lipiec, 2000), indicando o valor de 10% (0,10 $\text{m}^3 \text{m}^{-3}$) como limite crítico para aeração do solo. Inclusive obtiveram modelos para estimação de macroporos e microporos através do teor de areia e ρ , e comparados com dados da literatura com alta precisão (Stolf *et al.*, 2011).

Considerando a dinâmica da água no solo tem uma associação com o sistema poroso, pode considerar-se como um indicador da capacidade de armazenamento e disponibilidade de água para as plantas, com importância em projetos nas áreas de irrigação e drenagem (Jong Van Lier, De, 2010).

Grau de compactação

A densidade aparente seca normalizada ou grau de compactação do solo (GC) pode ser estimado pela relação entre a D_s e a D_{max} ou de referência, conforme (Håkansson, 1990):

$$DC = 100 \times \frac{p_s}{D_{max}} \quad \text{Eq. (6)}$$

Além da densidade do solo, podemos utilizar o grau de compactação para uma normalização dos valores de densidade do solo iniciais através da densidade do solo máxima obtida no ensaio de Proctor Normal (Santos *et al.*, 2005). Um indicador utilizado para quantificar os impactos do uso e manejo na qualidade física do solo é o grau de compactação (GC) (Betioli Júnior *et al.*, 2012; Lipiec *et al.*, 1991; Suzuki *et al.*, 2007). O GC é calculado pela razão entre a densidade do solo (D_s) no campo e a densidade máxima do solo (D_{max}) obtida em um teste de compactação, como o ensaio de Proctor (Dias Junior e Miranda, 2000; Oliveira *et al.*, 2010). Este método elimina as influências da composição granulométrica, mineralogia e matéria orgânica do solo, facilitando o estudo e comparação de sistemas de uso e manejo dos solos (Håkansson, 1990; Klein, Baseggio e Tiago, 2009). Dessa forma, o GC ajuda a contornar a comparação de resultados de densidade entre solos com diferentes características mineralógicas, de textura e de matéria orgânica (Betioli Júnior *et al.*, 2012).

Funções de modelos de pedotransferência

A amostragem de campo geralmente envolve altos custos, mão de obra e tempo. Por isso, edafólogos e engenheiros viram uma alternativa nos dados físicos e químicos passados (Manrique e Jones, 1991). Assim, desenvolveram modelos de regressão ou funções de pedotransferência (PTF) baseados em certas propriedades específicas do solo mensuráveis (carbono orgânico, teor de argila, entre outras). Essas PTFs são uma alternativa para prever características do solo em grandes extensões, podendo substituir as medições de densidade do solo quando sua medição direta não é viável (Benites *et al.*, 2007).

Ao momento de avaliar o desempenho das PTFs, tem que ter certo critério de selecionar as PTFs já que pode apresentar grandes diferenças quando são aplicadas em ambientes diferentes daqueles onde foram calibradas (Vos, De *et al.*, 2005).

No modelo de (Benites *et al.*, 2007) para prever a D_s foi desenvolvido para duas ordens de solos juntas de características semelhantes (Latosolos e Argissolos), numa primeira

instância foi predito pela função de argila, TOC, Fe₂O₃, WDC, SiO₂, areia e K⁺. Depois foi simplificado considerando os valores na Tabela 2.

Tabela 2. Funções de pedotransferência consideradas em regiões tropicais.

Autores	Modelos	R ²
(Benites <i>et al.</i> , 2007)	$D_s = 1.5597 - 0.0004 \text{ Clay} - 0.0077 \text{ OC} - 0.0004 \text{ Fe}_2\text{O}_3$	0.66
(Howard, Singer e Frantz, 1981)	$D_b = 1.91 - 0.0596 \text{ C} - 0.0076 \text{ Wl} + 0.0019 \text{ S} + 0.0058 \text{ Fe(Ditionita)}$	0.986
(Pádua, Guerra e Zinn, 2015)	$D_s = 1,7169 + (0,0385 \times \text{Al}^{3+}) + (0,0032 \times \text{V}) - (0,0012 \times \text{profundidade}) - (0,0029 \times \text{silte}) - (0,0055 \times \text{argila}) - (0,0274 \times \text{P}) - (0,1035 \times \text{COS})$	0,61
(Bernoux <i>et al.</i> , 1998)	$D_b = 1.52(\pm 0.05) - 0.0038(\pm 0.0004)\text{clay} - 0.050(\pm 0.005)\text{OC} - 0.045(0.008)\text{pH} + 0.0010(\pm 0.0003)\text{ sand}$	0.56

C = teor de C orgânico; Wl = teor de água no limite líquido; S = areia total; Fe = ditionito Fe, Fe₂O₃ = óxido de ferro g kg⁻¹; Clay = teor de argila, Al³⁺ saturação por Al (m) em % em cmol_c dm⁻³; V = saturação por bases; Teores de P e P-rem, em mg dm⁻³; Profundidade = profundidade média em (cm) de cada camada amostrada.

No modelo simplificado de (Benites *et al.*, 2007) as variáveis que apresentaram melhor correlação foram o teor de argila, TOC e Fe₂O₃. O valor de SB foi substituído pelo Fe₂O₃ a conta da pouca relação com D_s. Em certo grau da interpretação do (Benites *et al.*, 2007) para dar importância ao Fe₂O₃ é a conta do (Motta, Curi e Franzmeier, 2002), já que os agregados de argila (caulinita e gibbsita) são estabilizados por altos teores de óxidos de Fe, matéria orgânica ou ambos (Motta, Curi e Franzmeier, 2002).

De acordo a (Pádua, Guerra e Zinn, 2015) na função para a base completa menos Argissolos (0-100 cm) inclui-o uma maior variedade de variáveis predictoras (Al³⁺, V, profundidade média, teor de silte, teor de argila, P e COS). No entanto, como há muitas variáveis, isso reduz sua aplicabilidade para estimativas (Minasny e Hartemink, 2011).

Tomando em conta informações sobre a compactibilidade inerente do solo, (Howard, Singer e Frantz, 1981) aplicou pela regressão linear múltipla das propriedades físicas e químicas em solos florestais e de áreas de cultivos feitos com nas densidades aparentes secas máximas de Proctor.

De acordo com (Benites *et al.*, 2007) no Brasil, as pesquisas de (Bernoux *et al.*, 1998) e (Tomasella e Hodnett, 1998) forneceram a primeira linha de base para a previsão de Db a partir das propriedades dos solos da bacia amazônica.

(Bernoux *et al.*, 1998) mediante o procedimento de regressão múltipla passo a passo, mostrou-se que o teor de argila, o carbono orgânico e o pH eram os melhores preditores de Db. Além que encontrou maiores teores de óxido de Fe livres nos horizontes B. Já (Tomasella e Hodnett, 1998) ajustaram regressões lineares múltiplas para estimar a Db a partir dos teores de areia, silte e argila. (Manrique e Jones, 1991) relataram que a capacidade preditiva dos modelos de regressão para estimar a Db dos solos dos EUA melhorou quando os dados foram divididos por subordens, exceto para Aridisols, Entisols e Mollisols.

(Bernoux *et al.*, 1998) ao momento de tomar em conta o melhor predictor da Ds mediante a regressão múltipla passo a passo, determinou ao conteúdo de argila respondendo por 37% da variação e na adição do teor de CO aumentou a variação explicada para quase 50%. No caso de solos arenosos foi melhor predizer com o conteúdo de CO e conteúdo de areia.

Só argila isolada apresentou bons resultados e pode ser considerada uma alternativa para estimar a Db. Mas na situação de suprimir argila e CO se pode trabalhar com o conjunto de variáveis (teores de areia, capacidade de troca catiônica e teores de óxido de Fe) que também apresentarão bons resultados, aumentando o R² e diminuindo o SE. Tendo cuidado, já que as medições de óxido de Fe são geralmente escassas. (Bernoux *et al.*, 1998)

Sensor de constante elétrica (ThetaProbe ML2x)

Estão disponíveis no mercado diversos sensores capazes de medir a constante dielétrica com precisão aceitável. Dentre esses, um sensor relevante é o sensor de capacitância modelo ML2x Theta probe (Delta-T Devices Ltd., Cambridge, Reino Unido), utilizado para estimar o conteúdo de água do solo, o qual possui quatro hastes metálicas que geram um sinal de 100 MHz, pode estimar o teor de água do solo (Silva *et al.*, 2012).

A constante dielétrica, ou também conhecida como permissividade relativa, é uma propriedade física de um material que descreve sua capacidade de armazenar energia elétrica em um campo elétrico. De acordo com o manual da Theta Probe (LTD, 1995), a impedância (solo e água) tem dois componentes: a constante dielétrica aparente e a condutividade iônica, sendo que o sensor minimiza o efeito da condutividade iônica para que dependa, tanto quanto possível, da constante dielétrica aparente do solo. Essas mudanças causam uma onda estacionária de voltagem que aumenta ou reduz a voltagem produzida pelo oscilador de cristal, dependendo do meio ao redor das hastes de medição. Utiliza-se a diferença entre a voltagem no

oscilador e a refletida pelas hastes para medir a constante dielétrica aparente do solo (LTD, 1995). Os seguintes fatores devem ser levados em conta ao fazer medições:

- bolsas de ar
- raízes
- pedras e cascalhos
- ângulo de inserção da sonda
- não segurar ou mover a sonda ao fazer as leituras.

No contexto da medição da umidade do solo, a constante dielétrica refere-se à capacidade da água no solo de influenciar a propagação de ondas eletromagnéticas. A constante dielétrica da água diminui com o aumento da temperatura (LTD, 1995).

O tempo de movimento está relacionado à constante dielétrica do solo, que é proporcional à quantidade de água. Além que a dissipação do sinal está relacionada a concentração de sais na solução do solo (LTD, 1995).

O sensor de capacitância produz uma saída na forma de um valor de tensão (V), que é determinado por sua relação com a raiz quadrada da permissividade (constante) dielétrica aparente ($\epsilon^{0.5}$ ou índice de refração). Essa relação é calculada por meio de uma equação polinomial específica do sensor, conhecida como resposta do sensor (equação 10), conforme indicado por Delta-T Devices (1999)

$$\epsilon^{0.5} = 1.07 + 6.4V - 6.4V^2 + 4.7V^3 \quad \text{Eq. (7)}$$

A transformação do valor de saída do sensor em conteúdo de água do solo é obtida com o uso da relação entre o índice de refração e o conteúdo de água do meio. Essa relação é conhecida como calibração do solo (equação 11).

$$\epsilon^{0.5} = a_0 + a_1 * \theta \quad \text{Eq. (8)}$$

Onde: $\epsilon^{0.5}$ é a raiz quadrada da permissividade dielétrica; a_0 e a_1 são parâmetros de calibração específicos de cada solo; θ representa o conteúdo volumétrico de água, em $m^3 m^{-3}$; e V representa a leitura de saída do sensor, em volts

A calibração varia de acordo com os atributos do solo, seja por meio de uma equação linear ou de acordo com os coeficientes de ajuste dos valores $a_0 = 1.6$ e $a_1 = 8.4$. Em solos com matéria orgânica inferior a 7% e densidade aparente (D_s) $> 1,0 \text{ g dm}^{-3}$ (Silva *et al.*, 2012).

O sensor ML2x tem uma precisão de $\pm 0,05 \text{ m}^3 \text{ m}^{-3}$ (0-70°C), usando calibração de fábrica e $\pm 0,01 \text{ m}^3 \text{ m}^{-3}$, com calibração específica para o solo em que vai trabalhar, sem erros significativos para solos de 250 a 2.000 mS m^{-1} de condutividade elétrica (LTD, 1995).

Os sensores de constante dielétrica foram um dos primeiros a estimar o conteúdo de água com base no volume (θ_v), na temperatura, na resistência do solo e na umidade do (Mouazen e Al-Asadi, 2018)

Sensor de resistividade elétrica (X5xtal 250)

O método da Resistividade Elétrica do Solo (ρ) é usado para determinar a capacidade do solo de resistir ao fluxo de corrente elétrica gerado pelo sensor (Cássia Goulart Ferreira, de, Almeida Prado Bacellar, de e Moreira Viana, 2021; Samouëlian *et al.*, 2005; Silva *et al.*, 2023). A resistividade elétrica depende de vários atributos do solo, como a estrutura, a densidade, a porosidade e a umidade do solo (Costa *et al.*, 2014; Jeřábek, Zumr e Dostál, 2017; Kowalczyk, Maślakowski e Tucholka, 2014).

A resistividade elétrica do solo (ρ) é determinada pela aplicação de correntes elétricas ao solo por meio de dois eletrodos, denominados A e B, e pela medição das variações de potencial resultantes usando dois outros eletrodos, denominados M e N) (Jung, Drnevich e Abou Najm, 2013; Loke, 1999; Melo *et al.*, 2021a; Taiwo, Jong-Sub e Hyung-Koo, 2017). Essas medições são realizadas em diferentes arranjos espaciais para permitir diferentes tipos de sondagens/levantamentos, como a sondagem elétrica vertical, a qual pode ser realizada por meio do arranjo tipo Schlumberger (Samouëlian *et al.*, 2005). A ρ é calculada por meio deste arranjo aplicando-se a seguinte equação (equação 10):

$$\rho = \frac{4\pi a}{\left(1 + \frac{2a}{\sqrt{a^2 + 4b^2}} - \frac{2a}{\sqrt{4a^2 + 4b^2}}\right)} \frac{\Delta V}{I} \quad \text{Eq. (9)}$$

Onde:

- a é o espaçamento entre os eletrodos (m).
- b é a profundidade de penetração (m)
- ΔV é a diferença de potencial devido à aplicação de corrente elétrica (mV)
- I é a corrente elétrica injetada (mA).

O fator geométrico nas provas de campo é abordado em termos da separação entre os eletrodos, enquanto as propriedades dos eletrodos (comprimento e diâmetro) são ignoradas devido à sua escala relativamente pequena em comparação com a área de medição (Taiwo, Jong-Sub e Hyung-Koo, 2017)

Sensor de condutividade elétrica (Teros 12)

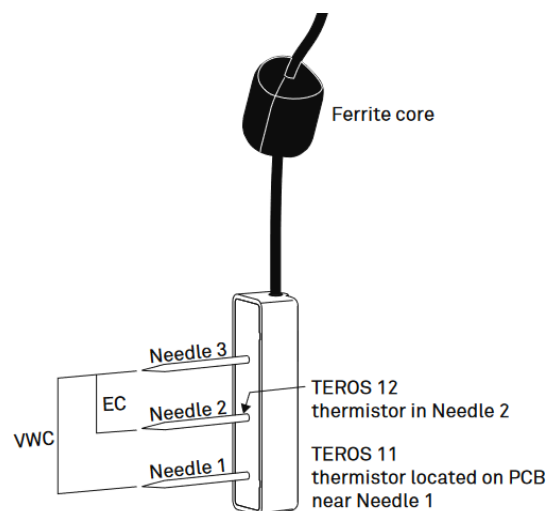
O equipamento Teros 12 é um sensor capaz de medir o conteúdo volumétrico de água (0 a 70% em solos minerais), a condutividade elétrica (0 a 20 dS m⁻¹ aparente), a permissividade elétrica e a temperatura do solo (-40 a 60°C).

A condutividade elétrica aparente (CE) é a capacidade de uma substância de conduzir eletricidade e pode ser usada para deduzir a quantidade de íons presentes em uma solução. A CE tem grande utilidade na estimativa da salinidade dos solos, especialmente em regiões áridas ou semiáridas (Baradaran Motie *et al.*, 2021).

Para determinar o conteúdo volumétrico de água, o sensor usou uma relação entre a permissividade dielétrica do substrato e seu conteúdo de água (um campo eletromagnético para medir a permissividade dielétrica do meio). Emitindo uma onda oscilante de 70 MHz pela agulha 1 e usando as agulhas 2 e 3 como referências para determinar o tempo de carregamento com base na permissividade dielétrica do meio, uma estimativa do volume de água foi calculada com a ajuda de um microprocessador (capacitância/domínio) para minimizar os efeitos da textura e da salinidade.

A temperatura foi estimada por meio das leituras do termistor integrado à agulha 2.

Figura 3. Corpo do sensor Teros 12/11 na vertical e agulhas na horizontal



Fonte: METER (2022)

Por fim, as leituras de CE foram medidas aplicando-se uma corrente elétrica alternada entre os dois eletrodos (agulha 2 e agulha 3) e medindo-se a resistência entre eles. A CE total foi obtida multiplicando-se o inverso da resistência (condutância) pela constante da célula (a razão entre a distância entre os eletrodos e sua área).

Para estimativa da CE, a resistência deve ser medida quando uma corrente elétrica alternada é aplicada a dois eletrodos. De acordo com o manual do METER (2022), para calcular a CE, o inverso da resistência (condutância) é multiplicado pela constante da célula, que é a razão entre a distância entre os eletrodos e sua área. No caso do sensor TEROS 12, as medições de CE aparente são ajustadas ou corrigidas a uma temperatura de 25 °C para obter a CE exata (equação 10)

$$EC_{25} = \frac{EC_T}{[1 + 0.019(T - 25)]}$$

Eq. (10)

Onde: EC_{25} representa a condutividade elétrica padronizada a 25 °C, EC_T refere-se à condutividade elétrica medida pela sonda na temperatura T , T é a temperatura no momento da medição °C.

Com relação à calibração do teor de água. De acordo com (METER, 2022), para a maioria dos tipos de solos minerais, uma equação de calibração só é necessária se a CE for de 0 a 8 dS m⁻¹ de extrato de saturação

$$\theta(m^3 m^{-3}) = 3.879 \times 10^{-4} \times RAW - 0.6956$$

Eq. (11)

Onde: θ representa o conteúdo volumétrico de água, em m³ m⁻³; RAW é a saída bruta do sensor.

Ao calibrar um solo mineral, é recomendável usar uma equação linear para obter uma previsão melhor, mas essa equação atinge um pico de aproximadamente 0,70 m³ m⁻³ em água pura. Por outro lado, recomenda-se que a modelagem em uma escala de 0 a 1,0 m³ m⁻³ seja feita com uma equação quadrática (Fragkos *et al.*, 2024). No entanto, (METER, 2022) não recomenda isso para solos minerais, porque muitas vezes torna a calibração menos precisa na faixa de conteúdo de água encontrada em solos minerais.

Com relação à margem de erro, ela é de ±3% em solos minerais típicos, ±5% + 0.01 dS m⁻¹ de 0 até 10 dS m⁻¹, e ±8% de 10 até 20 dS m⁻¹. Finalmente, a temperatura tem uma margem de erro de ±0.5°C de - 40 a 0°C, e ± 0.3°C de 0 até 60°C.

De acordo com trabalhos prévios, a compactação do solo aumenta a CE e diminui a ρ , pois o espaço poroso é reduzido e o contato entre as partículas do solo aumenta. Isso leva a um aumento no fluxo de corrente elétrica (Auerswald, Simon e Stanjek, 2001). Verificou-se também que a fração argila tem alta condutividade elétrica devido à sua alta concentração de cargas elétricas em sua superfície, conseqüentemente, em um ρ menor, afetando o processo de transmissão elétrica no solo (Calamita *et al.*, 2012)

Sensor de fluorescência por raios X

A espectrometria de fluorescência de raios X (XRF), foi desenvolvida principalmente para atividades industriais (Ribeiro *et al.*, 2017). Atualmente, essa tecnologia se expandiu para áreas como ciências ambientais, química, metalurgia, ciência do solo e agronomia (Weindorf, Bakr e Zhu, 2014)

A fluorescência de raios X com equipamento portátil (pXRF) é amplamente utilizada para identificar e quantificar elementos químicos em diferentes tipos de materiais. Essa técnica tem vantagens em relação a outras metodologias, pois é rápida e não gera resíduos químicos (Stockmann, Uta *et al.*, 2016; Weindorf, Bakr e Zhu, 2014). O pXRF pode ser utilizado tanto para a caracterização quanto para a predição de atributos do solo, pois detecta a energia de fluorescência específica liberada pelos elétrons de cada elemento presente no material analisado após ser atingido por raios X de alta energia (Weindorf, Bakr e Zhu, 2014)

De acordo com (Silva *et al.*, 2021), em geral, as amostras de solo que são coletadas para análise de raios X em laboratório *ex situ*, devem ser previamente secas, moídas e peneiradas para que não sejam afetadas pela umidade. Pois mesmo a água higroscópica aderida às partículas pode influenciar a absorção de parte dos raios X primários incidentes e o espalhamento dos raios X secundários (Ravansari, Wilson e Tighe, 2020; Stockmann, Uta *et al.*, 2016; Tassinari *et al.*, 2021).

Normalmente, os elementos de baixo número atômico ($Z < 26$) são mais afetados do que os elementos de número atômico mais e alguns elementos de alto número atômico, como Pb ($Z = 82$) e Zr ($Z = 40$), atingem concentrações subestimadas alto (Ge, Lai e Lin, 2005; Ribeiro *et al.*, 2018; Weindorf, Bakr e Zhu, 2014).

Uma área que ainda não foi desenvolvida em grande escala é a modelagem e a correção da influência da umidade na análise de pXRF de solos, rochas e sedimentos, conforme proposto por (Ge, Lai e Lin, 2005). Outro potencial levantado por (Ribeiro *et al.*, 2018) é quanto ao efeito da estrutura sobre as leituras do pXRF, isto é, os autores observaram que a densidade do solo e porosidade influenciaram nos resultados de Al e Fe quando foram estudados cinco solos e seus horizontes.

Algoritmo de Random Forest

O aprendizado de máquina é um método de análise de dados que automatiza a criação de modelos analíticos. É um ramo da Inteligência Artificial e se baseia na ideia de que os sistemas podem aprender com os dados, identificar padrões por si mesmos e tomar decisões com mínima intervenção humana (Mitchell, 1997).

Para ello, (Breiman, 2001) propuso o Random Forest como um método não linear para aumentar a precisão, promediando múltiplas árvores de decisão. Cada árvore é construída através de dois passos aleatórios: primeiro, usa-se uma amostra bootstrap para treinar cada árvore; segundo, em cada nó interno, utiliza-se um subconjunto aleatório de variáveis para gerar divisões.

Random Forest é uma evolução do Bagging cujo objetivo é reduzir a variância de um modelo estatístico. Ele simula a variabilidade dos dados por meio da extração aleatória de amostras bootstrap de um único conjunto de treinamento e agrega previsões sobre um novo registro (Aria, Cuccurullo e Gnasso, 2021; Breiman, 1996).

A principal característica dos modelos de Random Forest é a alta precisão preditiva alcançada por meio de abordagens não paramétricas baseadas em algoritmos iterativos. No entanto, isso gera os chamados modelos de "caixa preta", que não são interpretáveis através de parâmetros e formas funcionais, como ocorre com a análise de regressão clássica (Aria, Cuccurullo e Gnasso, 2021).

Isso foi demonstrado em trabalhos relacionados à comparação de modelos preditivos, como a (Andrade, Silva, Weindorf, Chakraborty, Faria, Guilherme, *et al.*, 2020) que avaliou a previsão de ordens e subordens de solos usando dois sensores (pXRF+NixPro) com base em três algoritmos de aprendizado de máquina ((Support Vector Machine with Linear Kernel (SVMLK), Rede Neuronal Artificial (ANN) e Random Forest (RF)). Sendo superior o algoritmo de Random Forest aos outros algoritmos, mesmo no estudo (Andrade *et al.*, 2021) para prever os micronutrientes disponíveis com algoritmos de regressão linear múltipla gradual (SMLR), suporte vector machine (SVM), reforço de gradiente extremo (XGB) e Random Forest (RF), o Random Forest foi o melhor modelo respeito aos índices de precisão e poder preditivo.

A avaliação dos modelos pode ser feita usando o R^2 , que descreve a proporção da variância total dos dados observados que pode ser explicada pelo modelo, cujo valor varia de 0 a 1, com valores mais altos indicando melhor concordância (Breiman, 1996). De acordo com (Breiman, 2001; Liaw e Wiener, 2002), os valores de R^2 para previsões de atributos do solo são considerados muito bons ($>0,81$), bons (0,61-0,8), razoáveis (0,41-0,6) e ruins (2), além disso, são classificados como moderadamente precisos ($1,4 \leq RPD \leq 2$) e imprecisos ($RPD < 1,4$). Portanto, os modelos com os maiores valores de R^2 e RPD, bem como os menores valores de RMSE, são considerados ideais para prever. Uma das métricas usadas para avaliar essa importância é o aumento percentual no erro quadrático médio (%IncMSE). Quanto maior o valor de %IncMSE, maior a importância da variável para o modelo (Liaw e Wiener, 2002).

Predição da Ds com sensores proximais

Para estimar tanto a densidade do solo quanto o teor de água no solo, é necessário ajustar os dados reais com o método padrão, desestruturando parte das amostras na estufa e ajustando-os de acordo com o modelo mais adequado para Ds ou θ_v .

A maioria das pesquisas para prever Ds utilizou sensores elétricos que estimavam θ_v . Por exemplo, (Tian *et al.*, 2020) combinou um TDR com a condutividade térmica do solo (λ) e

θ_v . Ou (Alaoui e Helbling, 2006), que avaliou a compactação do solo utilizando a reflectometria no domínio do tempo (TDR) com um sensor capacitivos SoilWatch10 em base modelos de redes neuronais.

Outra combinação, como (Al-Asadi e Mouazen, 2014a), utilizou técnicas vis-NIR e FDR para prever a Ds com base no conteúdo de umidade gravimétrica (ω), medido por espectroscopia de infravermelho próximo e visível (vis-NIRS), e no conteúdo de umidade volumétrica (θ_v), medido por reflectometria no domínio da frequência (FDR). Durante a análise de fusão de dados RNA (entrada de uma variável única ou múltiplas variáveis), os espectros vis-NIRS e a tensão de saída (V) do ThetaProbe foram combinados em uma matriz com ou sem frações de textura e conteúdo de matéria orgânica (MO) medidos em laboratório. A fusão de dados e RNA melhorou a precisão até ($R^2 = 0,98$ e $RMSE_p = 0,014 \text{ g}^{-1}$ e $0,015 \text{ cm}^3 \text{ cm}^{-3}$).

Protótipos para estimar a densidade aparente (Quraishi e Mouazen, 2013) estão sendo desenvolvidos com base em penetrômetros combinados com um espectrofotômetro visível e infravermelho próximo (vis-NIR), utilizando a resistência à penetração (PR), o conteúdo de umidade do solo (MC), o conteúdo de matéria orgânica (OMC) e o conteúdo de argila (CLC). O modelo de rede neural artificial (RNA) apresentou resultados muito promissores no treinamento ($R^2 = 0,92$ e $RMSE = 0,05 \text{ Mg m}^{-3}$), validação ($R^2 = 0,84$ e $RMSE = 0,08 \text{ Mg m}^{-3}$) e teste ($R^2 = 0,94$ e $RMSE = 0,04 \text{ Mg m}^{-3}$).

(Naderi-Boldaji *et al.*, 2014) Ao usar um sensor móvel que mede a condutividade elétrica aparente para diagnosticar a resistência à penetração e, portanto, a compactação, foi determinado que não houve correlações significativas entre EC e Ds, mas possivelmente teria mais relevância se o solo estivesse seco. Houve uma correlação significativa entre RP/θ_v , indicando que a EC é afetada por θ_v e pela textura do solo, não sendo suficiente para explicar a compactação de um solo.

Ao combinar sensores de respostas mecânicas, dielétricas e acústicas, foi observado que os espectros de distribuição de frequências acústicas distinguiram claramente a textura arenosa do solo (independentemente da Ds e do θ_v) (Naderi-Boldaji *et al.*, 2019). Além disso, o sensor dielétrico foi altamente correlacionado com o teor volumétrico de água do solo ($R^2 = 0,78$, erro médio absoluto (MAE) = $0,025 \text{ m}^3 \text{ m}^{-3}$), mas menos com relação à Ds. A fusão dos três sensores melhorou significativamente a previsão de θ_v ($R^2 = 0,93$, MAE = $0,014 \text{ m}^3 \text{ m}^{-3}$) e o grau de compactação do solo ($R^2 = 0,80$, MAE = 3,32%).

De acordo com sensores que medem a resistividade elétrica (Melo *et al.*, 2021a), foi determinado que a compactação leva a valores mais altos de θ para o mesmo valor de ρ . A modelagem simultânea de ρ conforme o DC e o grau de saturação (DS) mostrou que θ tem um

efeito maior sobre ρ do que a compactação do solo. O teor de água em solos mais compactados (DC = 90% e DC = 94%) se ajusta melhor ao modelo logarítmico. (Calamita *et al.*, 2012) destaca que os teores de argila e matéria orgânica podem aumentar a área de superfície específica, proporcionando uma alta densidade de carga, o que leva a uma maior condutividade elétrica.

Outras pesquisas utilizando espectroscopia com sensores infravermelhos (Shi *et al.*, 2023) determinaram que o modelo MIR de Ds teve melhor precisão do que os PTFs tradicionais, usando o modelo SVM com valor de ($R^2 = 0,81$) e (RMSEP = 0,132). A matéria orgânica do solo (SOM) foi identificada como o principal fator no modelo espectral de Ds do solo, superando significativamente os PTFs tradicionais. (Katuwal *et al.*, 2020) também desenvolveu modelos preditivos para estimar a Ds em diferentes horizontes. Os modelos de um único parâmetro apresentaram baixo poder preditivo, não conseguindo prever a BD acima de 1,62 g cm⁻³. Além disso, de acordo com os modelos multiparamétricos, que o SOC e o conteúdo de argila foram identificados como as variáveis mais importantes para prever a Ds.

Portanto, podemos concluir que a combinação de dados de vários parâmetros nos modelos é uma alternativa viável e promissora para a previsão de atributos do solo, gerando modelos mais robustos que individualmente. No entanto, ainda a fusão de sensores proximais está em desenvolvimento, precisando procurar as melhores variáveis e os modelos de previsão para poder prever certas características específicas em regiões tropicais que serão desenvolvidas com o tempo.

REFERÊNCIAS

- ABDELBAKI, A. M. Evaluation of pedotransfer functions for predicting soil bulk density for U.S. soils. **Ain Shams Engineering Journal**, v. 9, n. 4, p. 1611–1619, 1 dez. 2018.
- AJAYI, A. E. et al. Relation of strength and mineralogical attributes in Brazilian latosols. **Soil and Tillage Research**, v. 102, n. 1, p. 14–18, 1 jan. 2009.
- AKKER, J. J. H. VANDEN; CANARACHE, A. **Two European concerted actions on subsoil compaction**. 2001.
- ALAOUI, A.; HELBLING, A. Evaluation of soil compaction using hydrodynamic water content variation: Comparison between compacted and non-compacted soil. **Geoderma**, v. 134, n. 1–2, p. 97–108, 1 set. 2006.
- AL-ASADI, R. A.; MOUAZEN, A. M. Combining frequency domain reflectometry and visible and near infrared spectroscopy for assessment of soil bulk density. **Soil and Tillage Research**, v. 135, p. 60–70, 1 jan. 2014.
- ALVES, V. G. et al. Concentração de macronutrientes na parte aérea do feijoeiro (*Phaseolus vulgaris* L.) em função da compactação e classes de solos. **Ciência e Agrotecnologia**, v. 27, n. 1, p. 44–53, fev. 2003.
- ANDRADE, R. et al. Tropical soil order and suborder prediction combining optical and X-ray approaches. **Geoderma Regional**, v. 23, p. e00331, 1 dez. 2020.
- _____. Micronutrients prediction via pXRF spectrometry in Brazil: Influence of weathering degree. **Geoderma Regional**, v. 27, p. e00431, 1 dez. 2021.
- _____. Proximal sensor data fusion and auxiliary information for tropical soil property prediction: Soil texture. **Geoderma**, v. 422, p. 115936, 15 set. 2022.
- ARIA, M.; CUCCURULLO, C.; GNASSO, A. A comparison among interpretative proposals for Random Forests. **Machine Learning with Applications**, v. 6, p. 100094, 15 dez. 2021.
- ARMAS NOVOA, R.; GONZÁLEZ HARAMBOURE, Y. **Criterios sobre la compactación de suelos y el control de calidad de terraplenes**. [s.l.: s.n.]. Disponível em: <<https://www.researchgate.net/publication/258120503>>.
- AUERSWALD, K.; SIMON, S.; STANJEK, H. Influence of soil properties on electrical conductivity under humid water regimes. **Soil Science**, v. 166, n. 6, p. 382–390, jun. 2001.
- BALL, B. C. et al. The numeric visual evaluation of subsoil structure (SubVESS) under agricultural production. **Soil and Tillage Research**, v. 148, p. 85–96, 1 maio 2015.
- BALL, B. C.; BATEY, T.; MUNKHOLM, L. J. Field assessment of soil structural quality – a development of the Peerlkamp test. **Soil Use and Management**, v. 23, n. 4, p. 329–337, 1 dez. 2007.
- BARADARAN MOTIE, J. et al. A soft-computing approach to estimate soil electrical conductivity. **Biosystems Engineering**, v. 205, p. 105–120, maio 2021.

- BENEDET, L. et al. Soil texture prediction using portable X-ray fluorescence spectrometry and visible near-infrared diffuse reflectance spectroscopy. **Geoderma**, v. 376, p. 114553, 15 out. 2020.
- BENGOUGH, A. G. et al. Root elongation, water stress, and mechanical impedance: a review of limiting stresses and beneficial root tip traits. **Journal of Experimental Botany**, v. 62, n. 1, p. 59–68, 2011.
- BENITES, V. M. et al. Pedotransfer functions for estimating soil bulk density from existing soil survey reports in Brazil. **Geoderma**, v. 139, n. 1–2, p. 90–97, 15 abr. 2007.
- BERNOUX, M. et al. Bulk Densities of Brazilian Amazon Soils Related to Other Soil Properties. **Soil Science Society of America Journal**, v. 62, n. 3, p. 743–749, maio 1998.
- BETIOLI JÚNIOR, E. et al. Intervalo hídrico ótimo e grau de compactação de um latossolo vermelho após 30 anos sob plantio direto. **Revista Brasileira de Ciência do Solo**, v. 36, n. 3, p. 971–982, jun. 2012.
- BICKI, T. J.; SIEMENS, J. C. **Crop response to wheel trapnc soil compaction**. Transactions of the ASAE, v. 34, n. 3, p. 909–913, 1991.
- BIZ, J. DA C.; ANDRADE, M. DO E. S.; SILVA, E. C. S. Uma abordagem matemática para a previsão do adensamento das argilas saturadas. **Ciência e Natura**, v. 43, p. e2, 27 jun. 2022.
- BLAKE, G. R.; HARTGE, K. H. Bulk density. *Methods of soil analysis: Part 1 Physical and mineralogical methods*, v. 5, p. 363–375, 1986.
- BREIMAN, L. Bagging predictors. **Machine learning**, v. 24, p. 123–140, 1996.
- _____. Random forests. **Machine learning**, v. 45, p. 5–32, 2001.
- CALAMITA, G. et al. Electrical resistivity and TDR methods for soil moisture estimation in central Italy test-sites. **Journal of Hydrology**, v. 454–455, p. 101–112, ago. 2012.
- CARDOSO, D. P. et al. **Hydric erosion assessment by alteration on soil surface in forest systems**. p. 25–37, 1 dez. 2004.
- CARTER, L. M. **Wheel traffic is costly**. *Transactions of the ASAE*, v. 28, n. 2, p. 430–434, 1985.
- CÁSSIA GOULART FERREIRA, Q. DE; ALMEIDA PRADO BACELLAR, L. DE; MOREIRA VIANA, J. H. Evaluation of soil moisture by electrical resistivity in Oxisols of the central Brazilian savanna. **Geoderma Regional**, v. 26, p. e00408, 1 set. 2021.
- CONLIN, T. S. S.; DRIESSCHE, R. DEN. Response of soil CO₂ and O₂ concentrations to forest soil compaction at the long-term soil productivity sites in central British Columbia. **Canadian Journal of Soil Science**, v. 80, n. 4, p. 625 – 632, 2000.
- CORRÊA, J. B. D. et al. Influência da compactação na concentração de nutrientes da parte aérea da cana-de-açúcar, em três tipos de solos. **Revista STAB Açúcar, Álcool e Subprodutos**, v. 19, p. 34–37, 2001.

- COSTA, M. M. et al. Moisture content effect in the relationship between apparent electrical conductivity and soil attributes. **Acta Scientiarum. Agronomy**, v. 36, n. 4, p. 395, 21 ago. 2014.
- CUETO, O. G.; CORONEL, C. E. I.; SUÁREZ, M. H. Análisis de los factores que provocan compactación del suelo agrícola. **Revista Ciencias Técnicas Agropecuarias**, v. 18, n. 2, p. 57–63, 2009.
- CULLEY, J. L. B.; LARSON, W. E. Susceptibility to Compression of a Clay Loam Haplaquoll. **Soil Science Society of America Journal**, v. 51, n. 3, p. 562–567, 1 maio 1987.
- DEFOSSEZ, P.; RICHARD, G. Models of soil compaction due to traffic and their evaluation. **Soil and Tillage Research**, v. 67, n. 1, p. 41–64, 1 ago. 2002.
- DEXTER, A. R.; TANNER, D. W. Time dependence of compressibility for remoulded and undisturbed soils. **Journal of Soil Science**, v. 25, n. 2, p. 153–164, 1974.
- DIAS JÚNIOR, M. DE S. **Compression of three soils under long-term tillage and wheel traffic**. [s.l.] Michigan State University. Department of Crop and Soil Sciences, 1994.
- DÍAS JUNIOR, M. DE S. et al. Física do solo. UFLA ed. [s.l.: s.n.].
- DIAS JUNIOR, M. DE S.; MARTINS, P. C. C. **Ensaio de compressão uniaxial e modelos de capacidade de suporte de carga do solo**. Manual de métodos de análise de solo, v. 3, p. 152–171, 2017.
- DIAS JUNIOR, M. DE S.; MIRANDA, E. E. V. DE. Comportamento da curva de compactação de cinco solos da região de Lavras (MG). **Ci. Agrotec**, v. 24, p. 337–346, 2000.
- DIAS JUNIOR, M.; PIERCE, F. J. O processo de compactação do solo e sua modelagem. **Revista Brasileira de Ciência do Solo**, v. 20, n. 2, p. 175–182, 1996.
- DIAS JUNIOR, M. S. Compactação do solo. Tópicos em ciência do solo. **Sociedade Brasileira de Ciência do Solo**, v. 1, p. 55–94, 2000.
- DIAS JUNIOR, M. S.; ESTANISLAU, W. T. **Grau de compactação e retenção de água de latossolos submetidos a diferentes sistemas de manejo**. [s.l.: s.n.]. Disponível em: <<https://www.scielo.br/j/rbcs/a/SZK8MDkmYd38TsYCKFgKkxk/?format=pdf&lang=pt>>. Acesso em: 4 fev. 2023.
- EVANS, J.; RUFFING, D.; ELTON, D. **Compaction**. Em: [s.l.: s.n.]. p. 85–118.
- FAO & ITPS. Status of the world's soil resources (SWSR)—**Main report. Food and Agriculture Organization of the United Nations and intergovernmental technical panel on soils**, v. 650, p. 373, 2015.
- FARIA, A. J. G. DE et al. Prediction of soil organic matter content by combining data from Nix ProTM color sensor and portable X-ray fluorescence spectrometry in tropical soils. **Geoderma Regional**, v. 28, p. e00461, 1 mar. 2022.
- FERREIRA, M. M. et al. Física do Solo. Lavras: Editora UFLA, 2003. 79 p. il. Texto Acadêmico, 2003.

- FRAGKOS, A. et al. Response of the TEROS 12 Soil Moisture Sensor under Different Soils and Variable Electrical Conductivity. **Sensors**, v. 24, p. 2206, jul. 2024.
- GAMEDA, S. et al. High axle load compaction and corn yield. **Transactions of the ASAE**, v. 28, n. 6, p. 1759–1765, 1985.
- GAUTRONNEAU, Y.; MANICHON, H. Guide méthodique du profil cultural. [s.l.] **Groupe d'études d'application et de recherche en agriculture**, 1987.
- GE, L.; LAI, W.; LIN, Y. Influence of and correction for moisture in rocks, soils and sediments onin situ XRF analysis. **X-Ray Spectrometry**, v. 34, n. 1, p. 28–34, jan. 2005.
- GIAROLA, N. F. B. et al. Método de avaliação visual da qualidade da estrutura aplicado a Latossolo Vermelho Distroférrico sob diferentes sistemas de uso e manejo. **Ciência Rural**, v. 39, n. 8, p. 2531–2534, nov. 2009.
- GIAROLA, N. F. B.; SILVA, A. P. DA. Conceitos sobre solos coesos e hardsetting. **Scientia Agricola**, v. 59, n. 3, p. 613–620, set. 2002.
- GONZÁLEZ CUETO, O.; IGLESIAS CORONEL, C. E.; HERRERA SUÁREZ, M. Análisis de los factores que provocan compactación del suelo agrícola. **Revista Ciencias Técnicas Agropecuarias**, v. 18, n. 2, p. 57–63, 2009.
- GROHMANN, F. Porosidade. **Elementos de pedologia**, EDUSP, São Paulo-SP, p. 77–84, 1975.
- GUIMARÃ ES, R. M. L.; BALL, B. C.; TORMENA, C. A. **Improvements in the visual evaluation of soil structure**. 2011.
- GUPTA, S. C. **Development of guides for estimating the ease of compaction of world soils**. 1984.
- GUPTA, S. C.; ALLMARAS, R. R. Models to assess the susceptibility of soils to excessive compaction. Em: **Advances in soil science**. [s.l.] Springer, 1987. p. 65–100.
- HÅKANSSON, I. A method for characterizing the state of compactness of the plough layer. **Soil and Tillage Research**, v. 16, n. 1–2, p. 105–120, 1 abr. 1990.
- HÅKANSSON, I.; LIPIEC, J. A review of the usefulness of relative bulk density values in studies of soil structure and compaction. **Soil and Tillage Research**, v. 53, n. 2, p. 71–85, 1 jan. 2000.
- HÅKANSSON, I.; VOORHEES, W. B.; RILEY, H. Vehicle and wheel factors influencing soil compaction and crop response in different traffic regimes. **Soil and tillage research**, v. 11, n. 3–4, p. 239–282, 1988.
- HAMZA, M. A.; ANDERSON, W. K. Soil compaction in cropping systems: A review of the nature, causes and possible solutions. **Soil and Tillage Research**, v. 82, n. 2, p. 121–145, 1 jun. 2005.

HEUSCHER, S. A.; BRANDT, C. C.; JARDINE, P. M. Using Soil Physical and Chemical Properties to Estimate Bulk Density. **Soil Science Society of America Journal**, v. 69, n. 1, p. 51–56, jan. 2005.

HILLEL, D. 10 - Soil Compaction and Consolidation. Em: HILLEL, D. (Ed.). . Introduction to Soil Physics. San Diego: **Academic Press**, 1982. p. 176–199.

HORN, R. Compressibility of arable land in Impact of water and external forces on soil structure. Selected papers of the 1st Workshop on soilphysics and soilmechanics, Hannover 1986. **Catena**. Supplement (Giessen), n. 11, p. 53–71, 1988.

HORN, R.; LEBERT, M. Soil Compactability and Compressibility. **Developments in Agricultural Engineering**, v. 11, n. C, p. 45–69, 1 jan. 1994.

HOWARD, R. F.; SINGER, M. J.; FRANTZ, G. A. Effects of Soil Properties, Water Content, and Compactive Effort on the Compaction of Selected California Forest and Range Soils. **Soil Science Society of America Journal**, v. 45, n. 2, p. 231–236, 1981.

IMHOFF, S. et al. **Physical Quality Indicators and Mechanical Behavior of Agricultural Soils of Argentina**. PLOS ONE, v. 11, n. 4, p. e0153827, 21 abr. 2016.

JEŘÁBEK, J.; ZUMR, D.; DOSTÁL, T. Identifying the plough pan position on cultivated soils by measurements of electrical resistivity and penetration resistance. **Soil and Tillage Research**, v. 174, p. 231–240, 1 dez. 2017.

JOHANNES, A. et al. To what extent do physical measurements match with visual evaluation of soil structure? **Soil and Tillage Research**, v. 173, p. 24–32, 1 nov. 2017.

JONG VAN LIER, Q. DE. Física do solo. [s.l.] SBCS, 2010.

JUANG, T. C.; UEHARA, G. Effects of ground-water table and soil compaction on nutrient element uptake and growth of sugarcane. 1972.

JUNG, S.; DRNEVICH, V. P.; ABOU NAJM, M. R. New methodology for density and water content by time domain reflectometry. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 139, n. 5, p. 659–670, 2013.

KATUWAL, S. et al. Predicting the dry bulk density of soils across Denmark: Comparison of single-parameter, multi-parameter, and vis–NIR based models. **Geoderma**, v. 361, 2020.

KAUR, R.; KUMAR, S.; GURUNG, H. P. A pedo-transfer function (PTF) for estimating soil bulk density from basic soil data and its comparison with existing PTFs. **Soil Research**, v. 40, n. 5, p. 847–858, 2002.

KAY, B. D. Rates of change of soil structure under different cropping systems. **Advances in Soil Science 12**: Volume 12, p. 1–52, 1990.

KELLER, T. et al. Long-Term Soil Structure Observatory for Monitoring Post-Compaction Evolution of Soil Structure. **Vadose Zo. J.** 16, 1–16, 2017.

- KLEIN, A. V.; BASEGGIO, M.; TIAGO, M. **Indicadores da qualidade física de um Latossolo Vermelho distrófico típico sob plantiodireto escarificado**. v. dez, n. 9, p. 2475–2481, 2009.
- KONDO, M. K.; DIAS JUNIOR, M. S. Efeito do manejo e da umidade no comportamento compressivo de três latossolos. **Revista Brasileira de Ciência do Solo**, v. 23, n. 3, p. 497–506, set. 1999.
- KOWALCZYK, S.; MAŚLAKOWSKI, M.; TUCHOLKA, P. Determination of the correlation between the electrical resistivity of non-cohesive soils and the degree of compaction. **Journal of Applied Geophysics**, v. 110, p. 43–50, 1 nov. 2014.
- LARSON, W. E. et al. Control and Avoidance of Soil Compaction in Practice. **Developments in Agricultural Engineering**, v. 11, n. C, p. 597–625, 1 jan. 1994.
- LARSON, W. E.; ALLMARAS, R. R. Management factors and natural forces as related to compaction. **Compaction of agricultural soils**, 1971.
- LEBERT, M.; HORN, R. A method to predict the mechanical strength of agricultural soils. **Soil and Tillage Research**, v. 19, n. 2–3, p. 275–286, 1 fev. 1991.
- LIAW, A.; WIENER, M. Classification and Regression by randomForest. [s.l: s.n.]. Disponível em: <<http://www.stat.berkeley.edu/>>.
- LIMA, C. L. R. et al. Heterogeneidade da compactação de um latossolo vermelho-amarelo sob pomar de laranja. [s.l: s.n.].
- LIMA, R. P. DE et al. Impact of initial bulk density and matric suction on compressive properties of two Oxisols under no-till. **Soil and Tillage Research**, v. 175, p. 168–177, 1 jan. 2018.
- LIPIEC, J. et al. Soil physical properties and growth of spring barley as related to the degree of compactness of two soils. **Soil and Tillage Research**, v. 19, n. 2–3, p. 307–317, 1 fev. 1991.
- LIPIEC, J. et al. Effects of soil compaction on root elongation and anatomy of different cereal plant species. **Soil and Tillage Research**, v. 121, p. 74–81, 1 maio 2012.
- LOKE, M. H. Electrical imaging surveys for environmental and engineering studies. A practical guide to, v. 2, p. 70, 1999.
- LTD, D.-T. D. **ThetaProbe soil moisture sensor type ML1**, user manual Cambridge, , 1995.
- LUECK, E.; RUEHLMANN, J. Resistivity mapping with GEOPHILUS ELECTRICUS — Information about lateral and vertical soil heterogeneity. **Geoderma**, v. 199, p. 2–11, 1 maio 2013.
- MANCINI, M. et al. From sensor data to Munsell color system: Machine learning algorithm applied to tropical soil color classification via NixTM Pro sensor. **Geoderma**, v. 375, p. 114471, out. 2020.
- MANRIQUE, L. A.; JONES, C. A. Bulk Density of Soils in Relation to Soil Physical and Chemical Properties. **Soil Science Society of America Journal**, v. 55, n. 2, p. 476–481, 1991.

MC GARRY, D.; SHARP, G. A rapid, immediate, farmer-usable method of assessing soil structure condition to support conservation agriculture. **Conservation agriculture: environment, farmers experiences, innovations, socio-economy, policy**, p. 375–380, 2003.

MCBRIDE, R. A. Estimation of density—moisture—stress functions from uniaxial compression of unsaturated, structured soils. **Soil and Tillage Research**, v. 13, n. 4, p. 383–397, 1989.

MELO, L. B. B. DE et al. Effect of compaction on the relationship between electrical resistivity and soil water content in Oxisol. **Soil and Tillage Research**, v. 208, 1 abr. 2021.

MINASNY, B.; HARTEMINK, A. E. Predicting soil properties in the tropics. **Earth-Science Reviews**, v. 106, n. 1–2, p. 52–62, 1 maio 2011.

MITCHELL, T. M. **Machine learning**. [s.l.] McGraw-hill New York, 1997. v. 1

MOME FILHO, E. A. et al. Compared performance of penetrometers and effect of soil water content on penetration resistance measurements. **Revista Brasileira de Ciência do Solo**, v. 38, p. 744–754, 1 maio 2014.

MOTTA, P. E. F.; CURTI, N.; FRANZMEIER, D. P. **Relation of soils and geomorphic surfaces in the Brazilian Cerrado**. Em: The cerrados of Brazil: ecology and natural history of a neotropical savanna. [s.l.] Columbia University Press, 2002. p. 13–32.

MOUAZEN, A. M.; AL-ASADI, R. A. Influence of soil moisture content on assessment of bulk density with combined frequency domain reflectometry and visible and near infrared spectroscopy under semi field conditions. **Soil and Tillage Research**, v. 176, p. 95–103, 1 mar. 2018.

NADERI-BOLDAJI, M. et al. Feasibility study on the potential of electrical conductivity sensor Veris® 3100 for field mapping of topsoil strength. **Biosystems Engineering**, v. 126, p. 1–11, 1 out. 2014.

_____. A mechanical-dielectric-high frequency acoustic sensor fusion for soil physical characterization. **Computers and Electronics in Agriculture**, v. 156, p. 10–23, 1 jan. 2019.

NASTA, P. et al. Evaluating pedotransfer functions for predicting soil bulk density using hierarchical mapping information in Campania, Italy. **Geoderma Regional**, v. 21, p. e00267, 1 jun. 2020.

NBR, A. 7182: Solo—Ensaio de compactação. Rio de Janeiro, 2016.

NEGI, S. C. et al. **Crop performance as affected by traffic and tillage in a clay soil**. TRANSACTIONS of the ASAE, v. 23, n. 6, p. 1364–1368, 1980.

NELSON BEUTLER, A. et al. **Efeito da compactação na produtividade de cultivares de soja em latossolo vermelho**. v. 30, p. 787–794, 2006.

NEVE, S. DE; HOFMAN, G. Influence of soil compaction on carbon and nitrogen mineralization of soil organic matter and crop residues. **Biology and fertility of soils**, v. 30, p. 544–549, 2000.

- OLIVEIRA, V. S. et al. Compactação de um argissolo amarelo distrocoeso submetido a diferentes manejos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 9, p. 914–920, set. 2010.
- PÁDUA, E. J. DE; GUERRA, A. R.; ZINN, Y. L. Modelagem da Densidade do Solo em Profundidade sob Vegetação Nativa em Minas Gerais. **Revista Brasileira de Ciência do Solo**, v. 39, n. 3, p. 725–736, jun. 2015.
- PAHUJA, R. Development of semi-automatic recalibration system and curve- **Revista Brasileira de Ciência do Solo** fit models for smart soil moisture sensor. *Measurement*, v. 203, p. 111907, nov. 2022.
- PANAYIOTOPOULOS, K. P.; PAPADOPOULOU, C. P.; HATJIOANNIDOU, A. Compaction and penetration resistance of an Alfisol and Entisol and their influence on root growth of maize seedlings. **Soil and Tillage Research**, v. 31, n. 4, p. 323–337, 1 set. 1994.
- PATEL, A. et al. Soil compaction. Em: *Progressive Agriculture: Recent Trends and Innovation*. [s.l: s.n.]. p. 136.
- PEERLKAMP, P. K. **A visual method of soil structure evaluation**. 1959.
- PEIXOTO, D. S. et al. A soil compaction diagnosis method for occasional tillage recommendation under continuous no tillage system in Brazil. **Soil and Tillage Research**, v. 194, p. 104307, 1 nov. 2019.
- PENTOS, K.; PIECZARKA, K.; SERWATA, K. The Relationship between Soil Electrical Parameters and Compaction of Sandy Clay Loam Soil. 2021.
- PROCTOR, R. Fundamental principles of soil compaction. *Engineering news-record*, v. 111, n. 13, 1933.
- PULIDO MONCADA, M. et al. Visual field assessment of soil structural quality in tropical soils. **Soil and Tillage Research**, v. 139, p. 8–18, 1 jun. 2014.
- QURAIISHI, M. Z.; MOUAZEN, A. M. A prototype sensor for the assessment of soil bulk density. **Soil and Tillage Research**, v. 134, p. 97–110, 1 nov. 2013.
- RADZI, H. M. et al. An overview of asphalt mix designs using various compactors. *IOP Conference Series: Materials Science and Engineering*, v. 512, n. 1, p. 12031, abr. 2019.
- RAEESI, M. et al. Prediction of soil organic matter using an inexpensive colour sensor in arid and semiarid areas of Iran. **Soil Research**, v. 57, n. 3, p. 276, 2019.
- RAGHAVAN, G. S. V.; ALVO, P.; MCKYES, E. Soil compaction in agriculture: a view toward managing the problem. **Advances in Soil Science: Soil Degradation Volume 11**, p. 1–36, 1990.
- RAGHAVAN, G. S. V.; MCKYES, E. Physical and hydraulic characteristics in compacted clay soils. **Journal of Terramechanics**, v. 19, n. 4, p. 235–242, 1 jan. 1983.

RAMOS, F. T. et al. Curvas de compactação de um Latossolo Vermelho-Amarelo: com e sem reuso de amostras. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, p. 129–137, 2013.

RAVANSARI, R.; WILSON, S. C.; TIGHE, M. Portable X-ray fluorescence for environmental assessment of soils: Not just a point and shoot method. **Environment International**, v. 134, p. 105250, 1 jan. 2020.

REICHARDT, K.; TIMM, L. C. Soil, plant and atmosphere. [s.l.] **Springer**, 2014.

REICHERT, J. M. et al. Reference bulk density and critical degree-of-compactness for no-till crop production in subtropical highly weathered soils. **Soil and Tillage Research**, v. 102, n. 2, p. 242–254, 1 mar. 2009.

_____. Compressibility and elasticity of subtropical no-till soils varying in granulometry organic matter, bulk density and moisture. **CATENA**, v. 165, p. 345–357, 1 jun. 2018.

REINERT, D. J. **Soil structural form and stability induced by tillage in a typic hapludalf**. 1992.

REIS, A. M. H. DOS et al. Hierarchical pedotransfer functions for predicting bulk density in Brazilian soils. **Scientia Agricola**, v. 81, p. e20220255, 11 dez. 2024.

RIBEIRO, B. T. et al. Portable X-ray fluorescence (pXRF) applications in tropical Soil Science. **Ciência e Agrotecnologia**, v. 41, n. 3, p. 245–254, jun. 2017.

_____. The Influence of Soil Moisture on Oxide Determination in Tropical Soils via Portable X-ray Fluorescence. **Soil Science Society of America Journal**, v. 82, n. 3, p. 632–644, maio 2018.

RIBEIRO, K. et al. Propriedades físicas do solo, influenciadas pela distribuição de poros, de seis classes de solos da região de Lavras-MG. **Ciencia E Agrotecnologia - CIENC AGROTEC**, v. 31, 1 ago. 2007.

RICHARD, G. et al. Field study of soil compaction due to traffic in northern France: pore space and morphological analysis of the compacted zones. **Soil and Tillage Research**, v. 51, n. 1–2, p. 151–160, 1 jul. 1999.

RICHART, A. et al. Soil compacting: causes and effects Compactação do solo: causas e efeitos. *Semina* : **Ciências Agrárias**, 1 jan. 2009.

ROGER-ESTRADE, J. et al. Morphological characterisation of soil structure in tilled fields: from a diagnosis method to the modelling of structural changes over time., v. 79, n. 1, p. 33–49, 1 set. 2004.

SAMOUËLIAN, A. et al. Electrical resistivity **Soil and Tillage Research** survey in soil science: a review. *Soil and Tillage Research*, v. 83, n. 2, p. 173–193, 1 set. 2005.

SANTOS, G. A. DOS et al. Diferentes graus de compactação e fornecimento de fósforo influenciando no crescimento de plantas de milho (*Zea mays* L.) cultivadas em solos distintos. **Ciência e Agrotecnologia**, v. 29, n. 4, p. 740–752, ago. 2005.

SCHJØNNING, P. et al. Soil precompression stress, penetration resistance and crop yields in relation to differently-trafficked, temperate-region sandy loam soils. **Soil and Tillage Research**, v. 163, p. 298–308, nov. 2016.

SELADJI, S. et al. The effect of compaction on soil electrical resistivity: a laboratory investigation., v. 61, p. 1043–1055, 2010.

SHI, L. et al. Prediction of soil bulk **European Journal of Soil Science** density in agricultural soils using mid-infrared spectroscopy. **Geoderma**, v. 434, p. 116487, 1 jun. 2023.

SILVA, B. M. et al. Acurácia e calibração de sonda de capacitância em Latossolo Vermelho cultivado com cafeeiro. **Pesquisa Agropecuária Brasileira**, v. 47, n. 2, p. 277–286, fev. 2012.

SILVA, L. DE C. M. DA et al. Assessment of soil water content variability using electrical resistivity imaging in an Oxisol under conservation cropping systems. **Geoderma Regional**, v. 33, p. e00624, 1 jun. 2023.

SILVA, S. H. G. et al. Tropical soils characterization at low cost and time using portable X-ray fluorescence spectrometer (pXRF): Effects of different sample preparation methods. **Ciência e Agrotecnologia**, v. 42, n. 1, p. 80–92, fev. 2018.

_____. pXRF in tropical soils: Methodology, applications, achievements and challenges. **Advances in Agronomy**, v. 167, p. 1–62, 1 jan. 2021.

SMUCKER, A.; ERICKSON, A. E. Tillage and Compactive Modifications of Gaseous Flow and Soil Aeration. Em: [s.l: s.n.]. p. 205–221.

SOANE, B. D.; OUWERKERK, C. VAN. Soil compaction in crop production. **Elsevier ed.** [s.l: s.n.]. v. 1

SOIL SCIENCE SOCIETY OF AMERICA. Glossary of soil science terms Soil Science Society of America, 1997

STOCKMANN, U. et al. The Effect of Soil Moisture and Texture on Fe Concentration Using Portable X-Ray Fluorescence Spectrometers. Em: [s.l: s.n.]. p. 63–71.

STOLF, R. et al. Method to estimate soil macroporosity and microporosity based on sand content and bulk density. **Revista Brasileira de Ciência do Solo**, v. 35, n. 2, p. 447–459, abr. 2011.

STONE, L. F.; GUIMARÃES, C. M.; MOREIRA, J. A. A. Compactação do solo na cultura do feijoeiro. I: efeitos nas propriedades físico-hídricas do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 6, n. 2, p. 207–212, 2002.

SUZUKI, L. E. A. S. et al. Grau de compactação, propriedades físicas e rendimento de culturas em Latossolo e Argissolo. **Pesquisa Agropecuária Brasileira**, v. 42, p. 1159–1167, 2007.

SWAN, J. B. Soil compaction: causes, effects and control. [s.l.] Minnesota Extension Service, University of Minnesota, 1987.

SZATANIK-KLOC, A. et al. Soil compaction-induced changes of physicochemical properties of cereal roots. **Soil and Tillage Research**, v. 175, p. 226–233, 1 jan. 2018.

- TAIWO, S.; JONG-SUB, L.; HYUNG-KOO, Y. Analytical and experimental studies to obtain electrical resistivity in a small-scaled laboratory test. **GEOPHYSICS**, v. 82, p. 1–33, maio 2017.
- TASSINARI, D. et al. Determination method and strain-attribute interact in the calculation of precompression stress from soil compression curves. **Biosystems Engineering**, v. 210, p. 33–47, 1 out. 2021.
- TAYLOR, H. M.; ROBERSON, G. M.; PARKER JR, J. J. Soil strength-root penetration relations for medium-to coarse-textured soil materials. **Soil science**, v. 102, n. 1, p. 18–22, 1966.
- TEIXEIRA, A. F. DOS S. et al. Proximal sensor data fusion for tropical soil property prediction: Soil fertility properties. **Journal of South American Earth Sciences**, v. 116, p. 103873, 1 jun. 2022.
- TIAN, Z. et al. Estimating soil bulk density with combined commercial soil water content and thermal property sensors. **Soil and Tillage Research**, v. 196, p. 104445, 1 fev. 2020.
- TIMM, L. C. et al. Field spatial and temporal patterns of soil water content and bulk density changes. **Scientia Agricola**, v. 63, n. 1, p. 55–64, fev. 2006.
- TOMASELLA, J.; HODNETT, M. G. Estimating soil water retention characteristics from limited data in brazilian amazonia. **Soil Science**, v. 163, n. 3, 1998.
- TOMINAGA, T. et al. The use of a surface gamma-neutron gauge to explore compacted soil layers. **Soil Science - SOIL SCI**, v. 165, p. 665–676, 1 ago. 2000.
- TORMENA, C. A. et al. Densidade, porosidade e resistência à penetração em latossolo cultivado sob diferentes sistemas de preparo do solo soil bulk density, porosity and resistance to root penetration in an oxisol managed by different soil tillage systems. **Scientia Agricola**, v. 59, n. 4, p. 795–801, 2002.
- VAZ, C. M. P. et al. Modeling and correction of soil penetration resistance for varying soil water content. **Geoderma**, v. 166, n. 1, p. 92–101, 30 out. 2011.
- VEEN, B. W. The influence of mechanical impedance on the growth of maize roots. **Plant and Soil**, v. 66, p. 101–109, 1982.
- VINGIANI, S. et al. A multisensor approach coupled with multivariate statistics and geostatistics for assessing the status of land degradation: The case of soils contaminated in a former outdoor shooting range. **Science of The Total Environment**, v. 933, p. 172398, 10 jul. 2024.
- VISCARRA ROSSEL, R.; MCBRATNEY, A.; MINASNY, B. **Proximal Soil Sensing. Dordrecht: Springer Netherlands**, 2010. v. 1
- VOS, B. DE et al. Predictive Quality of Pedotransfer Functions for Estimating Bulk Density of Forest Soils. **Soil Science Society of America Journal**, 2005.
- WEINDORF, D. C.; BAKR, N.; ZHU, Y. Advances in Portable X-ray Fluorescence (PXRF) for Environmental, Pedological, and Agronomic Applications. **Advances in Agronomy**, v. 128, p. 1–45, 1 jan. 2014.

SECOND PART – PAPERS

PAPER 1 - PROXIMAL SENSORS FUSION AND MACHINE LEARNING ALGORITHM COMBINED TO IMPROVE SOIL COMPACTION PREDICTION

Authors:

Victor Enmanuel Rodas Arano^a; Rodas, V.E.A.

Lara Mota Corinto^b; Corinto, L.M.

Jean Marcos Pereira dos Santos Reis^c; Santos, J.S.

Milson Evaldo Serafim^d; Serafim, M.E.

Sérgio Henrique Godinho Silva^e; Silva, S.H.G.

Bruno Montoani Silva^{f,*}; Silva, B.M..

^a Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: victor.arano@estudante.ufla.br

^b Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: lara.corinto1@estudante.ufla.br

^c Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: jean.reis@estudante.ufla.br

^d Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: milsonserafim@gmail.com

^e Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: sergio.silva@ufla.br

^f Departamento de Ciência do Solo, Universidade Federal de Lavras (DCS/UFLA), Campus universitário, Caixa Postal 3037, CEP 37200-900, Lavras, Minas Gerais, Brazil. E-mail: brunom.silva@ufla.br

* Corresponding author. Tel.: +55 35 38291266; fax: +55 35 38291256.

E-mail address: brunom.silva@ufla.br (B.M. Silva).

Abbreviations:

θ , soil water content; θ_v , volumetric water content; ρ , soil electrical resistivity; EC, electrical conductivity; K_a or ϵ , constant dielectric; DC, degrees of compaction; DS, degree of saturation; Bd, bulk density; U, gravimetric water content; D_w , water density; PVC, polyvinyl chloride; LVdf, Latossolo Vermelho distroférico; LVAd, Latossolo Vermelho Amarelo distrófico; CO, organic carbon

Highlights

Soil compaction prediction with sensors reduces costs, time, and contamination

Excluding water content didn't affect accuracy but shifted importance of Fe, Si, Ti

pXRF outperformed electrical sensors in predicting compaction, enabling robust models

Key variables for LVdf models were Si, Al, Ti, Cu, Fe; for LVAd: Cu, EC, Al, Cr, Fe

As the soil compacts, some variables experience reduced variability

Abstract

Predicting adverse factors in agricultural production, like excessive soil compaction, is crucial for taking preventive measures that reduce costs, drying time, environmental contamination from chemical analyses, and the need for destructive sampling methods. Therefore, the objective of this research was to predict soil compaction by evaluating regression and classification models using Random Forest algorithms based on the integration of a wide range of proximal sensors. A total of 56 undisturbed samples were collected in PVC cylinders from two types of soils (LVdf and LVAd), which were subjected to different compaction degrees (70%, 80%, 90%, 100%, 110%) in the laboratory. Readings were taken with an X-ray fluorescence spectrometer (pXRF) to measure chemical concentration, an electrical resistivity sensor (X5xtal 250), an electrical conductivity sensor (Teros12), a dielectric constant sensor (ML2X), and volumetric water content, from saturation to drying. By integrating the sensors, robust and accurate regression models were obtained using Random Forest algorithms to predict compaction degree (DC), with $R^2=0.79$ for LVdf and LVAd, and $R^2=0.93$ when combining both soils. Excluding water content in the models did not significantly affect accuracy but did alter the importance of certain variables, such as Fe, Si, Ti, and Zn. When analyzed individually, the X-ray fluorescence sensor (pXRF) was better at predicting compaction compared to electrical sensors, achieving an R^2 of 0.78 for LVdf and LVAd, and $R^2=0.91$ when combining both soils. Although the classification models showed good performance, no clear distribution pattern of variables based on compaction degree was identified.

Keywords: soil structure; bulk density; random forest; soil electrical resistivity; soil dielectric constant; soil electrical conductivity; x-ray fluorescence

Graphical abstract



1. Introduction

Soil compaction is a serious threat to soil health and ecosystem services that impact food, fibers and bioenergy production due to its changes on soil structure-related properties (Arvidsson e Håkansson, 2014; Hamza e Anderson, 2005; Santana *et al.*, 2023). The main cause of soil compaction in agriculture is heavy vehicular traffic in inadequate (wet) conditions, and causes costs issues to farmers, like reduction in crop yield, more fertilizers and diesel application, and to the whole society, like fooding, erosion, greenhouse gas emissions are likely to escalate with climate change (Graves *et al.*, 2015; Keller *et al.*, 2019; Peixoto *et al.*, 2020). Soil compaction change the spatial arrangement of soil constituents resulting in reduction of pore space and increase in bulk density (Keller *et al.*, 2017), and this modified physical environment restrict root growth, decrease water movement and storage, nutrient availability and gases transport (Bengough, Bransby, *et al.*, 2011; Lipiec *et al.*, 2012; Or, Keller e Schlesinger, 2021; Szatanik-Kloc *et al.*, 2018) , impact water recharge (Santana *et al.*, 2023) and other natural hazards (Malehmir *et al.*, 2016).

Diagnosis of soil compaction is closely related to bulk density (Bd) and degree of compactness (DC) (also known as relative bulk density). DC is the ratio of field bulk density to a reference bulk density - determined by the maximum bulk density of the Proctor Normal test (Carter, 1990) - which is more independent of soil characteristics and has proven to be an effective indicator for identifying soil compaction that reduces crop yield (Reichert *et al.*, 2009).

Both the diagnosis of soil compaction and soil water content (θ) remain a challenge for farmers and technicians, despite advancements in methods and agricultural studies (Peixoto *et al.*, 2019). Conventional methods typically require destructive sampling of undisturbed soil in the field and laboratory analysis, which are often costly, labor-intensive, and time consuming. An alternative, more efficient approach from a spatial and temporal perspective involves the use of sensors capable of accurately estimating soil properties with minimal disturbance to it, while achieving relatively high precision (Brillante *et al.*, 2015; Romero-Ruiz *et al.*, 2018; Samouëlian *et al.*, 2005)

One advancement is the development of spectroscopy with the deployment of on-the-go or real-time proximal soil detection systems and scanners (Minasny e Hartemink, 2011), which typically work with electrical conductivity sensors using vertical and horizontal penetrometers (Macák *et al.*, 2019). The prediciton models improved when θ was added to predict Bd (Cho, Sudduth e Chung, 2016; Islam *et al.*, 2014). (Bittelli *et al.*, 2021) successful implemented algorithms with TDR techniques based on electrical permittivity to obtain both

Bd and θ_v . Another soil electrical property used to estimate Bd and soil compaction is electrical resistivity (Kowalczyk, Maślakowski e Tucholka, 2014; Melo *et al.*, 2021b; Seladji *et al.*, 2010) which are deployed in field using non-invasive geophysical methodologies such as Electrical Resistivity Tomography (ERT) (Besson *et al.*, 2004; Jeřábek, Zúmr e Dostál, 2017; Romero-Ruiz *et al.*, 2018; Silva *et al.*, 2023) for diagnosing soil compaction at different depths. This demonstrates the high efficiency of using proximal sensors with electrical pulses as a valuable tool for predicting soil bulk density, due to the interaction of electrical conduction within water-filled pores and the surface of clay particles, generally depending on soil structure (Besson *et al.*, 2004).

Other authors have demonstrated that integrating various technologies, methodologies, and variables can enhance prediction models through the fusion of proximal sensors, (Andrade *et al.*, 2022; Naderi-Boldaji *et al.*, 2019; Vingiani *et al.*, 2024). For example, to predict soil bulk density, (Tian *et al.*, 2020) combined thermal conductivity sensors with θ_v , (Al-Asadi e Mouazen, 2014a) combined an electrical permittivity sensor based on frequency domain reflectometry (FDR) ThetaProbe with visible and near-infrared spectroscopy (vis-NIRS), (Pentos, Pieczarka e Serwata, 2021) combined an in-field EC and magnetic susceptibility sensors showing promising results for evaluating soil compaction. Additionally, prototypes are being tested that combine a vis-NIR sensor with a penetrometer (Quraishi e Mouazen, 2013). As proposed by (Sudduth, Drummond e Kitchen, 2001) and widely used in the literature, the calibration approach can be used to quantify the within-field variations of a specific factor of interest that is large enough when compared to the variation promoted by the other factors on the electrical properties of the soil (e.g., soil salinity, texture and other soil properties), considered reasonably homogeneous. The calibrated electrical property measurement then reports the variation of the dominant factor.

Additionally, other sensors and methodologies that initially had different purposes have been integrated, such as X-ray fluorescence (XRF) spectrometry, which was primarily developed for industrial activities (Ribeiro *et al.*, 2017). Nowadays, this technology has expanded into fields like environmental science, chemistry, metallurgy, soil science, and agronomy (Weindorf, Bakr e Zhu, 2014). Over time, these techniques have been combined with data from other sensors, such as the NixPro color sensor and pXRF, along with machine learning algorithms, to enhance soil order characterization (Andrade, Silva, Weindorf, Chakraborty, Faria, Guilherme, *et al.*, 2020), to predict soil particle size fractions and soil textural classes (Andrade *et al.*, 2022), and also to predict soil fertility properties (Teixeira *et al.*, 2022b) with the sensor fusion of pXRF, visible near-infrared diffuse reflectance

spectroscopy (Vis-NIR), and NixPro™. This range of sensor fusions to predict soil characteristics has not yet been addressed with electrical sensors, which are particularly effective in measuring water content (θ_v) and has potential for other soil properties.

However, it should be noted that θ_v in the samples can lead to an underestimation of chemical elements (Silva *et al.*, 2018), as water absorbs part of the primary X-rays, affecting the readings (Stockmann, U. *et al.*, 2016). To achieve more accurate readings, it is recommended to pre-dry the samples to a moisture content of no more than 0.20 g g^{-1} or obtain saturated samples and apply correction factors (Kalnicky e Singhvi, 2001; Ribeiro *et al.*, 2017), and also to grind them finely ($< 2\text{mm}$) to increase X-ray intensity and thus detect higher element concentrations (Laiho e Perämäki, 2005; Maruyama *et al.*, 2008). Therefore, θ_v stands as one of the most important variables when estimating soil properties, which can affect the identification of the weight of the variables in the different prediction algorithms. Ribeiro *et al.*, (2017) found that SiO_2 and Al_2O_3 contents measured with pXRF were strongly correlated with bulk density and porosity when undisturbed soil samples were used, suggesting an influence of soil structure condition on Si and Al that still need to be addressed.

To contribute toward improving the efficiency of diagnosis of soil compaction, considering the potential of sensors and machine learning in advance smart agriculture solutions, the hypothesis of this study is that accurate prediction models for the degree of compactness can be obtained combining proximal sensors and the Random Forest algorithm. The aims of this study were: (1) to predict degree of compactness using regression model and fusion of proximal sensors data (pXRF, ML2x, X5xtal 250, TEROS12); (2) to test the effect of inclusion or not soil water content in the prediction of soil compaction with proximal sensors; (3) to compare potential of models of soil compaction prediction generated using electrical properties sensors (ρ , CE, Ka) with pXRF sensor; and (4) to predict the classification of soil compaction using classification model of Random Forest algorithm.

2. Material and methods

2.1. Soil sampling and preparation

The study was conducted in Lavras, in the state of Minas Gerais, Brazil, in native forest areas that preserve their structure without anthropic intervention. The predominant climate is classified as Cwb (Köppen), characterized by cold, dry winters and warm, humid summers (Alvares *et al.*, 2013). The average annual precipitation is 1,570 - 1621 mm, and annual temperatures range between 18 and 20 °C (Alvares *et al.*, 2013; Moraes, de *et al.*, 2023). The

first soil collection was carried out in a typical very clayey-textured *Latossolo Vermelho distroférico* according in Brazilian System of Soil Classification (Santos *et al.*, 2018) correspondent to Rhodic Hapludox in Soil Taxonomy (Staff, 1998). at geographical coordinates (21°13'44'' S, 44°58'46'' W), and the second point at geographical coordinates 21°12'13.7'' S, 44°59'15.9'' W for a clayey-textured *Latossolo Vermelho Amarelo distrófico* corresponds to a Typic Hapludox as classified by (Curi *et al.*, 2017). A characterization of the soils sampled is presented in Table 1.

Table 1. Soil physical and chemical characterization and classification according to the Brazilian Soil Classification System (SiBCS) (Santos *et al.*, 2018) and corresponding US Soil Taxonomy (Staff, 1998)

Identifi- cation	Soil USDA Classification	Bedrock	Physical properties of soil ¹					Soil chemical properties ²			
			(g kg ⁻¹)			(Mg m ⁻³)		(g kg ⁻¹)			
			Clay	Sand	Silt	Bdi	Bdref	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	TiO ₂
LVdf Acrudox	Anionic	Gabro	746	81	173	1.08	1.44	131	263	232	13
LVAd	Typic Hapludox	Granite -gneiss	483	386	131	1.09	1.48	158	250	76.7	9.5

Bdi: initial bulk density sampled in native vegetation area. *Bdref*: reference of maximum bulk density obtained with Proctor test (Carter, 1990). 1 Determined by Pipette method at 10-20 cm depth. 2 Data extracted from Ribeiro *et al.* (2017) for 80-100 cm depth

A total of 28 undisturbed soil samples were collected from each point at A horizon in PVC cylinders with an average diameter of 11.20 cm and an average height of 6.80 cm, following the methodology of (Hadzick *et al.*, 2011; Melo *et al.*, 2021b; Michot *et al.*, 2003). One end of the cylinder was made narrower so that the cylinders could penetrate the soil more easily. The topsoil 0-10 cm was removed to reduce the effect of excess organic matter on sensor readings.

In the laboratory, the excess soil was removed from the top and bottom of the cylinders to ensure a precise volume of undisturbed soil. Initially, for each soil class treatment, three samples were assigned to determine the initial soil water content at the time of sampling, initial

bulk density, and to perform the textural analysis using the pipette method. All other samples were then slowly saturated by capillarity with distilled water through the base of the cylinders for 72 hours (Melo *et al.*, 2021b).

Hence, samples were equilibrated at -10 kPa in a tension table model pF Suction Plate (ecoTech, Germany), to achieve condition close to their field capacity. In order to achieve different degree of compactness (DC, eq. 1) for each soil class, samples were compacted at field capacity performing a uniaxial compression test with the aid of a modified consolidometer (Dias Junior e Martins, 2017), including a plastic cylinder (0,02 cm height) of same diameter the PVC cylinders. To achieve five different DC (70%, 80%, 90%, 100% and 110%), the compression height necessary to reduce bulk density was estimated based on initial soil water content (obtained with the three initial samples) and the bulk density at sampling time. For those samples with 100% and 110% compaction degree, a Proctor test was performed until the calculated height was reached. Therefore, a total of 50 samples for two soil classes grouped in five replicates and five DC was calculated according to (Eq. 1):

$$DC = \frac{Bd}{Bd_{ref}} \times 100\% \quad (1)$$

Where *DC* is degree of compactness; *Bd* is soil bulk density ($g\ cm^{-3}$); and *Bd_{ref}* is reference bulk density ($g\ cm^{-3}$) achieved through a proctor test according (Carter, 1990)

Once the samples were compacted, they were again saturated and weighed on an analytical balance to obtain the soil water content at saturation. Subsequently, they were analyzed with the different sensors every two days, taking into account the weight of the samples on the day of measurement until they were completely dried in a forced air oven at 60°C over approximately 25 days. Simultaneously, the samples were weighed to calculate the soil water content in each analysis. This was done to establish a correlation with the sensor readings during the moisture loss process of the samples.

2.2. X5xtal 250 sensor analyses

The soil electrical resistivity determination is used to determine the soil's ability to resist the flow of electric current generated by a power source (Cássia Goulart Ferreira, de, Almeida Prado Bacellar, de e Moreira Viana, 2021; Samouëlian *et al.*, 2005; Silva *et al.*, 2023). Soil electrical resistivity (ρ) readings were measured with an X5xtal 250 resistivity meter sensor (Auto Energia, Minas Gerais, Brazil) and the help of two multimeters. The measurements were made using Wenner array by applying electric current (I) to the soil through electrode A to electrode B together with measurement of the resulting potential variations (V) using two other electrodes (designated M and N) (Loke, 1999; Melo *et al.*, 2021b; Taiwo, Jong-Sub e Hyung-

Koo, 2017). According to the Wenner methodology, the 4 electrodes (A, M, N, B) were inserted linearly at a distance of 2 cm between each at a depth of 4 cm. The resistivity (ρ) was calculated as follows (Eq. 2).

$$\rho = \frac{4\pi a}{\left(1 + \frac{2a}{\sqrt{a^2 + 4b^2}} - \frac{2a}{\sqrt{4a^2 + 4b^2}}\right)} \times \frac{\Delta V}{I} \quad (2)$$

where: a is the separation of electrodes (m); b is the penetration depth (m); ΔV is potential difference due to application of electric current (mV); and I is injected electric current (mA).

2.3. Teros 12 sensor analyses

The Teros 12 (Meter Group, USA/Germany) is a sensor capable of measuring volumetric water content (0 to 70% in mineral soils), electrical conductivity (0 to 20 dS m⁻¹ apparent) and soil temperature (-40 to 60°C) (Meter, 2018).

To determine the volumetric water content, the sensor used a relationship between the dielectric permittivity of the substrate and its water content (an electromagnetic field to measure the dielectric permittivity of the medium). According to (Fragkos *et al.*, 2024), calibrating water content can present issues due to the low operating frequency of the sensor. The soil's electrical conductivity (σ) affects the determination of apparent dielectric permittivity, which can lead to inaccurate estimations of θ . By emitting an oscillating wave of 70 MHz through needle 1 and using needles 2 and 3 as references to determine the charging time based on the dielectric permittivity of the medium, an estimate of the water volume was calculated with the help of a microprocessor (capacitance/domain) to minimize the effects of texture and salinity. The temperature was estimated through the readings of the thermistor integrated into needle 2. Finally, the EC readings were measured by applying an alternating electric current between the two electrodes (needle 2 and needle 3) and measuring the resistance between them. The bulk EC was obtained by multiplying the inverse of the resistance (conductance) by the cell constant (the ratio between the distance between the electrodes and their area). Since the EC is dependent on the ambient temperature, an adjustment should be made if it reaches 25°C with the respective equation (Eq 3):

$$EC_{25} = \frac{EC_T}{1 + 0.019(T - 25)} \quad (3)$$

where EC_{25} is the normalized EC at 25 °C, EC_T is the EC measured by the probe at temperature T , and T is the temperature at the time of measurement.

The data obtained through the sensor were: volumetric water content (θ_v) in cubic meters per cubic meter (m³ m⁻³); temperature in degrees Celsius (°C); and electrical conductivity

in millisiemens per centimeter (mS cm^{-1}), but for dimensional consistency, it was converted to microsiemens per centimeter ($\mu\text{S cm}^{-1}$).

2.4. ThetaProbe ML2x sensor analyses

In addition to the sensors mentioned earlier, a dielectric capacitance probe, the ML2x Theta probe (Delta-T Devices Ltd., Cambridge, UK), was also used. This sensor employs four rods that generate a 100 MHz sinusoidal electromagnetic signal within the soil (Al-Asadi e Mouazen, 2014b). The soil's impedance (apparent dielectric constant and ionic conductivity) mainly depends on the soil's apparent dielectric constant, which is influenced by the water content. The difference in the reflected voltage helps determine this dielectric constant, allowing the device to infer the soil water content θ_v .

This relationship between the sensor output in (V), is determined by an equation in relation to the square root of the apparent dielectric constant ($\epsilon^{0.5}$ or refractive index) (Silva *et al.*, 2012), using a sensor-specific polynomial equation, known as the sensor response (Equation 5), as indicated (Delta-T Devices Ltd, 1995)

$$\epsilon^{0.5} = 1.07 + 6.4V - 6.4V^2 + 4.7V^3 \quad (5)$$

The transformation of the sensor output value into soil water content is obtained using the relationship between the refractive index and the water content of the medium. This relationship, known as soil calibration (Eq 6), allows the determination of water content.

$$\epsilon^{0.5} = a_0 + a_1 * \theta \quad (6)$$

Where: $\epsilon^{0.5}$ is the square root of the dielectric permittivity; a_0 and a_1 are calibration parameters specific to each soil; θ represents the volumetric water content, in $\text{m}^3 \text{m}^{-3}$; and V represents the sensor output reading, in volts.

This calibration varies according to soil attributes, using either a linear equation where coefficients are adjusted to $a_0 = 1.6$ and $a_1 = 8.4$. In soils with organic matter less than 7% and bulk density $> 1.0 \text{ g dm}^{-3}$. Additionally, the ML2x sensor has an accuracy of $\pm 0.05 \text{ m}^3 \text{m}^{-3}$ within a temperature range of 0 to 70°C (Silva *et al.*, 2012). The data obtained with ML2x was in standart mineral soil calibration achived with an DL6 Data Logger (Delta-T Devices Ltd., Cambridge, UK).

2.5. pXRF sensor analyses

A pXRF spectrometer model Tracer 5g (Bruker®, USA) was used to obtain the composition of chemical elements through scanning with an X-ray tube of maximum power of 4W, voltage of 15-50 keV and current 5-200 μA . Using a silicon drift detector with graphene window and resolution $< 145 \text{ eV}$. This allowed the detection of elements from Mg to U in mg

kg^{-1} , based on each element response to electronic excitation by different frequencies of the X-ray spectrum (Weindorf, Bakr e Zhu, 2014). The scans were performed on each undisturbed sample, protecting the sensor window with a plastic film and placing the sensor in direct contact with the samples, from a degree of saturation to nearly dry. Each sample was scanned 5 times to ensure accuracy and quality, each repetition lasted 60 s (two beams) on the soil contaminant-nutrient curve with a dwell time of 30 s per beam (Cean *et al.*, 2024).

To ensure the quality and accuracy of the data generated by the pXRF, the equipment was calibrated using the (check sample) before use. The pXRF spectrometer detected the concentration of twenty-nine elements in all soil samples. Regardless of the soil's water content, only the elements consistently detected by the sensor throughout the process (saturated-dry) were used. Therefore, only 16 chemical elements were considered: Mg, Al, Si, P, K, Ca, Ti, V, Cr, Mn, Fe, Ni, Cu, Zn, As, and Zr.

2.6. Data analyses and modeling

Once the data were preprocessed by removing variables with missing values, the complete data set was obtained, which included both predictor variables and response variables. For the predictor variables, all data from proximal sensors were grouped, including pXRF (chemical elements as percentages of Mg, Al, Si, P, K, Ca, Ti, V, Cr, Mn, Fe, Ni, Cu, Zn, As, Zr), X5xtal 250 (ρ in Ω m), Teros12 (EC in $\mu\text{S cm}^{-1}$), ML2X (ϵ as a dimensionless unit), and volumetric water content (θ_v in $\text{m}^3 \text{m}^{-3}$) obtained with standard dry-oven method.

The Random Forest was used due to its high performance reported in the literature (Andrade, Silva, Weindorf, Chakraborty, Faria, Mesquita, *et al.*, 2020). Regardless of the classification or regression model, the following criteria were applied for the response variable: In the Random Forest classification model, the compaction degrees were considered, grouped into five categories (70%, 80%, 90%, 100%, and 110%). In the Random Forest regression models, the actual compaction values of the samples were considered, expressed as numerical variables (with a minimum range of 70.66 % and a maximum of 119.75%).

Subsequently, the R software (version 4.3.0) (Team, 2021) and the "caret" package (Kuhn *et al.*, 2020) were used to randomly divide the dataset into modeling (training) and validation (testing) subsets, consisting of 80% and 20% of the total samples, respectively. When training the Random Forest model for both classification and regression models, it was fitted with 500 trees and the number of variables considered for each split was set to 5. In the first approach, all variables were considered to observe their interaction and determine the importance of the variables, which were then grouped into different combinations, as expressed in the table (Table 1), to build prediction models tested.

Table 2. Summary of the tested classification models on LVdf and LVAd soils showing the set of input variables in each model.

Target variable	Soil	Models	Explanatory variables	N° of predictor variables
DC_70%	LVdf + LVAd ¹	1	pXRF + ML2x + TEROS12 + X5xtal 250 + θ_v	19
	LVdf ²	1	pXRF + ML2x + TEROS12 + X5xtal 250 + θ_v	19
	LVAd ³	1	pXRF + ML2x + TEROS12 + X5xtal 250 + θ_v	19
	LVdf + LVAd ¹	2	pXRF + ML2x + TEROS12 + X5xtal 250	18
	LVdf ²	2	pXRF + ML2x + TEROS12 + X5xtal 250	18
	LVAd ³	2	pXRF + ML2x + TEROS12 + X5xtal 250	18
	LVdf + LVAd ¹	3	pXRF + θ_v	16
	LVdf ²	3	pXRF + θ_v	16
	LVAd ³	3	pXRF + θ_v	16
DC_80%	LVdf + LVAd ¹	4	pXRF	15
	LVdf ²	4	pXRF	15
	LVAd ³	4	pXRF	15
DC_90%	LVdf + LVAd ¹	5	ML2x + TEROS12 + X5xtal 250 + θ_v	4
	LVdf ²	5	ML2x + TEROS12 + X5xtal 250 + θ_v	4
	LVAd ³	5	ML2x + TEROS12 + X5xtal 250 + θ_v	4
DC_100%	LVdf + LVAd ¹	6	ML2x + TEROS12 + X5xtal 250	3
	LVdf ²	6	ML2x + TEROS12 + X5xtal 250	3
	LVAd ³	6	ML2x + TEROS12 + X5xtal 250	3
DC_110%	LVdf + LVAd ¹	6	ML2x + TEROS12 + X5xtal 250	3
	LVdf ²	6	ML2x + TEROS12 + X5xtal 250	3
	LVAd ³	6	ML2x + TEROS12 + X5xtal 250	3

pXRF - portable X-ray fluorescence spectrometry; *ML2x* - apparent dielectric constant sensor; *X5xtal 250* - soil electrical resistivity sensor; *TEROS 12* - soil electrical conductivity sensor

1 n = 475, 2 n = 230, 3 n = 245

By building the prediction model with all the combined data from the two soil classes, a total of (9500 data) was obtained for LVdf (4600) and LVAd (4900). The following approaches were considered to verify the relationship between water content and sensors. Thus, in the first approach, all variables were taken into account (pXRF+X5xtal 250+ML2X+Teros12+θv). The second approach, all variables without water content were taken into account (pXRF+X5xtal 250+ML2X+Teros12). For the third approach, the relationship between chemical elements and water content was considered (pXRF+θv), the fourth approach only chemical elements were taken into account (pXRF) without the influence of water content. Another approach was to consider electrical sensors and their interaction with water content (X5xtal 250+ML2X+Teros12+θv). Finally, the last approach no longer considered the relationship with water content (X5xtal 250+ML2X+Teros12).

2.7. Evaluating models performance

To measure the prediction accuracy of the classification models of the Random Forest algorithms, Accuracy was used to measure the performance of the model, with the following equation (Eq 7):

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \text{ or } \frac{Pc}{N} \quad (7)$$

Where, *VP (True Positives): Correct predictions of the positive class*, *VN (True Negatives): Correct predictions of the negative class*, *FP (False Positives): Incorrect predictions of the positive class*, *FN (False Negatives): Incorrect predictions of the negative class*, *Pc is the sum of the main diagonal of the confusion matrix (predicted soil textural classes)*, *N is the total number of validation samples*.

On the other hand, in the case of class imbalance, the Kappa index was used to correct the agreement between the model predictions and the real ones, by means of a random agreement (Eq 8)

$$Kappa = \frac{Po - Pe}{1 - Pe} \quad (8)$$

where, *Po is the observed agreement*, and *Pe is the probability of random agreement (Landis e Koch, 1977)*

Given that Accuracy is a value ranging from 0 to 1, it is calculated by dividing the sum of correctly classified samples (the main diagonal of the confusion matrix) by the total number of samples (the closer to 1, the higher the accuracy) (Congalton, 1991). On the other hand, the Kappa coefficient ranges from -1 to 1, considering the number of correctly classified samples,

the total number of samples, and misclassifications to provide prediction results (the closer to 1, the higher the reliability of the prediction) (Cohen, 1960; Landis e Koch, 1977)

To evaluate the values of the regression models using the Random Forest algorithm, we used the metrics of comparison of the predicted values with the observed values by means of the coefficient of determination (R^2) (Eq 9), the root mean square error (RMSE) (Eq 10), the mean absolute error (MAE) (Eq 10)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - m_i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - m_i| \quad (10)$$

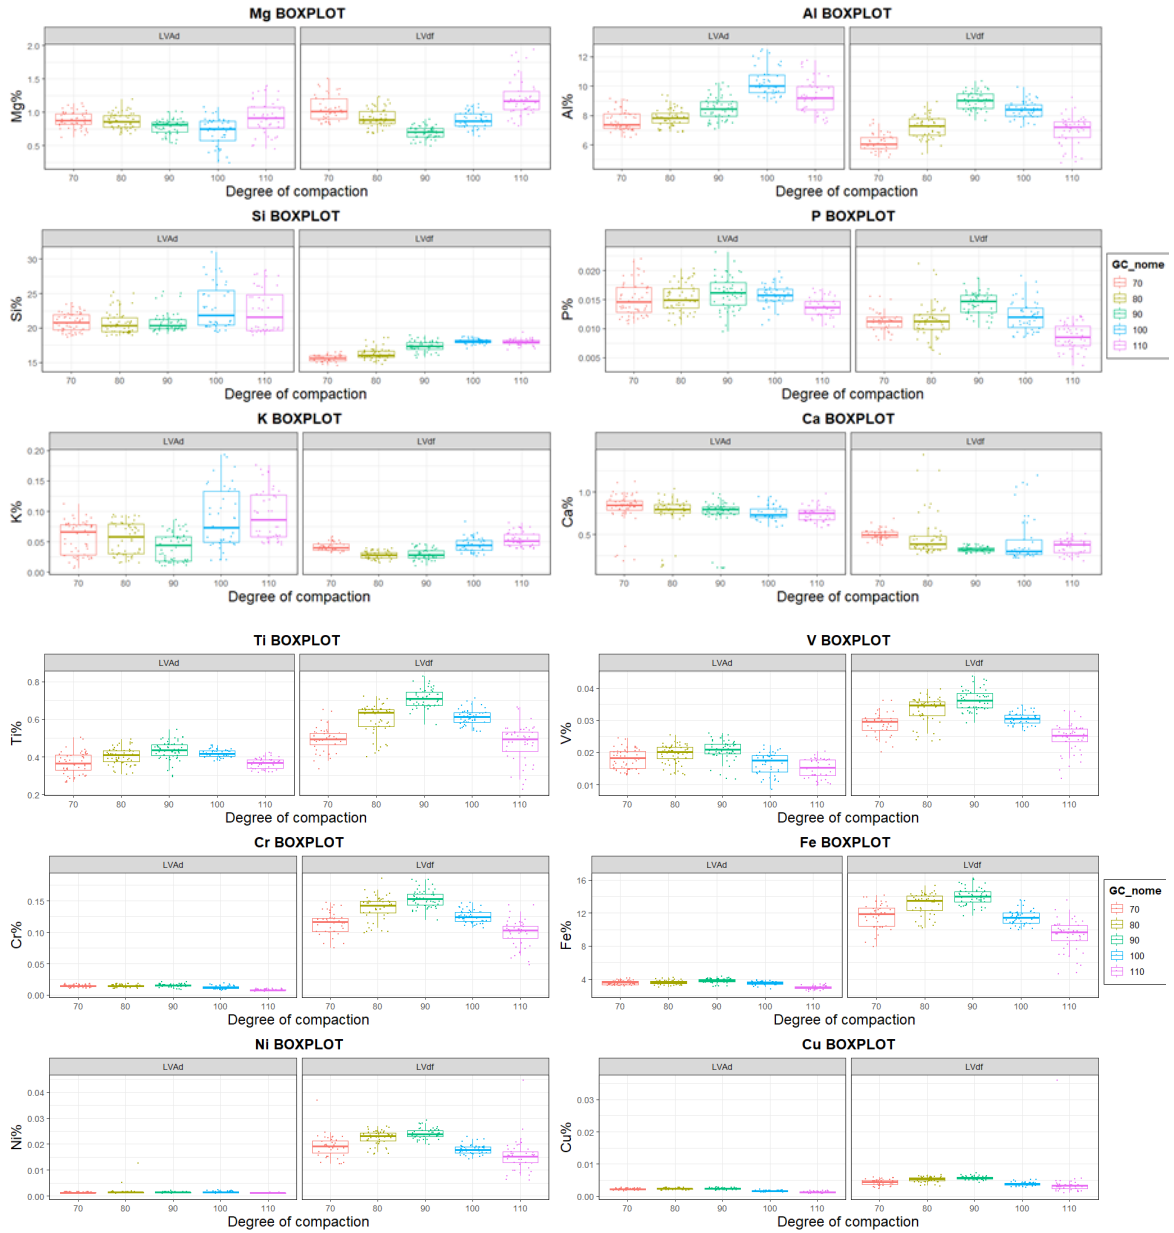
where, n : number of observations, y_i : estimated value by the model, m_i : measured value by the chemical analysis, SD : standard deviation of the observed values.

The models with the highest R^2 and lowest RMSE were considered optimal for predicting laboratory analyses.

3. Results and discussion

3.1. Characterization of variables and principal component analysis

Figure 1 presents the boxplot distribution of proximal sensor outputs, chemical and electrical variables, and soil water content, in undisturbed soil samples from two soils under five crescent degrees of compaction. A clear difference can be seen in certain variables in relation to soil order as well as their interaction with the degree of compaction. Certain variables such as the content of Si, Ca, Ti, V, Cr, Fe, Ni and As show a clear differentiation pattern between the two soil orders, as in the work (Andrade, Silva, Weindorf, Chakraborty, Faria, Guilherme, *et al.*, 2020) that found high levels of Cr, Fe and Ni in LVdf in relation to other soil orders, due to the mafic parent rocks. Results of LVdf showed high concentrations of Fe, which are derived from iron oxides such as hematite (Fe_2O_3) that are markably present from gabbro derived soils, as well as higher contents of As, Cr and Ni. On the other hand, in the LVAd soil order, a higher concentration of Si and Ca was observed compared to LVdf. The reduction of Si in the LVdf may be due to a higher degree of weathering (Kämpf, Marques e Curi, 2012) and a high drainage that affected the sum of bases and therefore the content of K and Ca due to an acid soil.



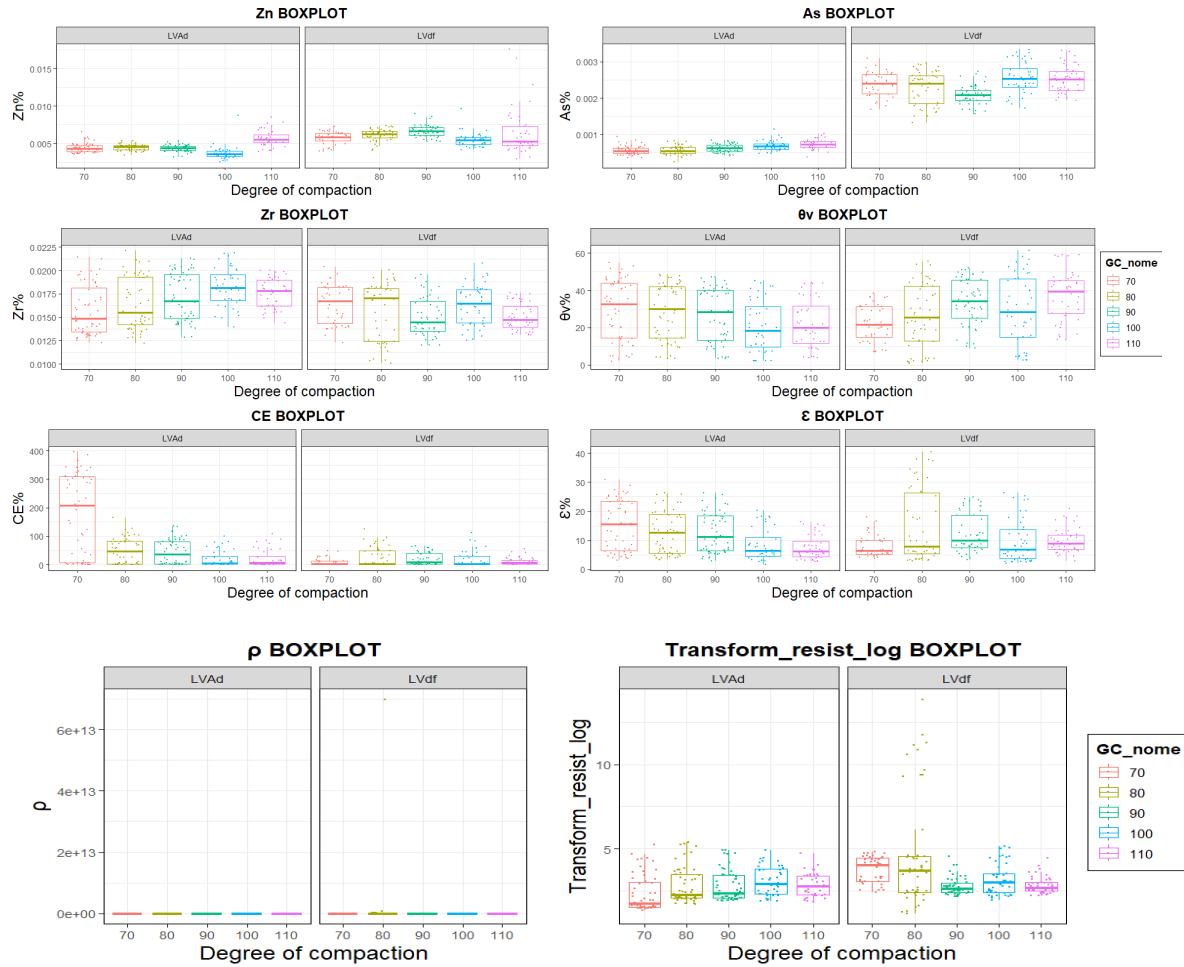


Fig 1. Boxplots comparing all sensor variables obtained by (Mg, Al, Si, P, K, Ca, Ti, Ti, V, Cr, Fe, Ni, Cu, Zn, As, Zr, θ_v , EC, ϵ , ρ) as a function of compaction degree and order of Brazilian tropical soils Lvdf and LVAd.

Chemical variables interacted among soil classes and with the degree of compaction. As the soil becomes more compacted, the Si content increased in the LVdf, while the Ca content decreased in both LVdf and LVAd. In LVAd, as compaction increased, the percentage of Al increased, except at the 110% compaction level. Conversely, Cu content decreases with increasing compaction in LVAd. As and Zr content increased slightly with increasing soil compaction, but occurred only for LVAd soils.

For electrical sensors, EC shows the interquartile range (IQR) significantly larger in LVAd GC 70% compared to other compaction levels, which tend to cluster around the median as soil compaction increases. EC did not show clear relation with DC for LVdf, but for LVAd show a tendency of negative correlation. Previously laboratory study reports influence ($r = 0.71$) on EC by bulk density but less than the influence of the water content (Bertermann e Schwarz, 2017), confirming (Rhoades, Corwin e Lesch, 1999) theoretical model in which EC is function of θ_v , the electrical conductivity of the soil water, soil bulk density, and the electrical

conductivity of the soil particles. The ϵ exhibits a wider interquartile range (IQR) in non-compacted soils, indicating greater data dispersion. But as compaction increases, the data become more concentrated around the median, resulting in lower variability, except for DC 70% for LVdf. Also, ϵ reduces with DC increases for LVAd. As formulated by (Jung, Drnevich e Abou Najm, 2013) and (Curioni *et al.*, 2018) and implemented also by (Bittelli *et al.*, 2021), bulk density is directly proportional to voltage attenuation and inversely proportional to ϵ . However, for LVdf, the results did not show this relationship.

In relation to the ρ , the raw data vary from 14 to 6.979E+13 Ω m, hence to facilitate visualization on boxplot a constant of 0.5 had to be added for its subsequent transformation in logarithm in base ten in order to stabilize the variation of the data. Both raw data and transformation data did not show a clear pattern between DC and ρ .

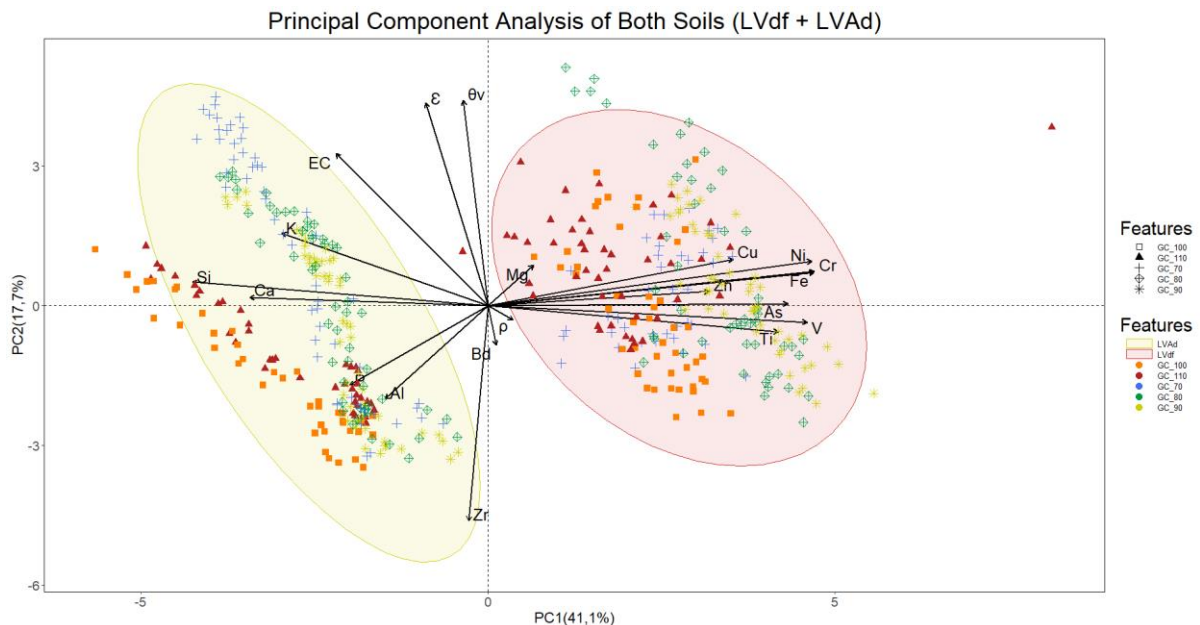


Fig 2. Principal Component Analysis (PCA) for different degrees of compaction in two orders of clay-textured LVdf and semi-clay-textured LVAd soils, through water content (θ_v), chemical composition (pXRF) and electrical attributes (ML2x, X5xtal 250, TEROS 12). pXRF data: Mg, Al, Si, P, K, Ca, Ti, V, Cr, Fe, Ni, Cu, Zn, As, Zr in percent.

The combination of PCA1 (41.1%) and PCA2 (17.7%) on the Fig. 2 explained 58.8% of the total variance or retained 58.8% of the original data variability. According to the grouping of the ellipses and the magnitude or dimension of the variables, a clear distinction between the two orders of soils was evidenced, confirming Fig. 1, the magnitude of Iron is positively correlated with the LVdf due to its pedogenetic characteristics of high content of iron oxides such as hematite (Fe_2O_3) - stable in well drained environment - that gives it the characteristic

reddish color, likewise explaining a negative correlation with Ca and K due to high drainage. On the other hand, the LVAd has a high positive correlation with Si and Al content due to the characteristics of presence of 1:1 clay minerals, basically kaolinitic, sand fraction rich in quartz (Martín-García *et al.*, 2023) typically of granite-gneiss bedrocks.

Fig. 2 highlights, independent of soil order, a strong correlation and therefore control of soil water content on soil electrical properties (ϵ , EC and ρ), mainly on ϵ also confirmed by Pearson correlation coefficient ($r = 0,85$; $p < 0,01$; Fig. 10 supplementary files). Also, soil electrical properties do not well distinguished soil orders or degrees of compaction as soil chemical composition. In general, is noteworthy that greater DC (100 and 110%) tend to correlate with Si, Ca and Al.

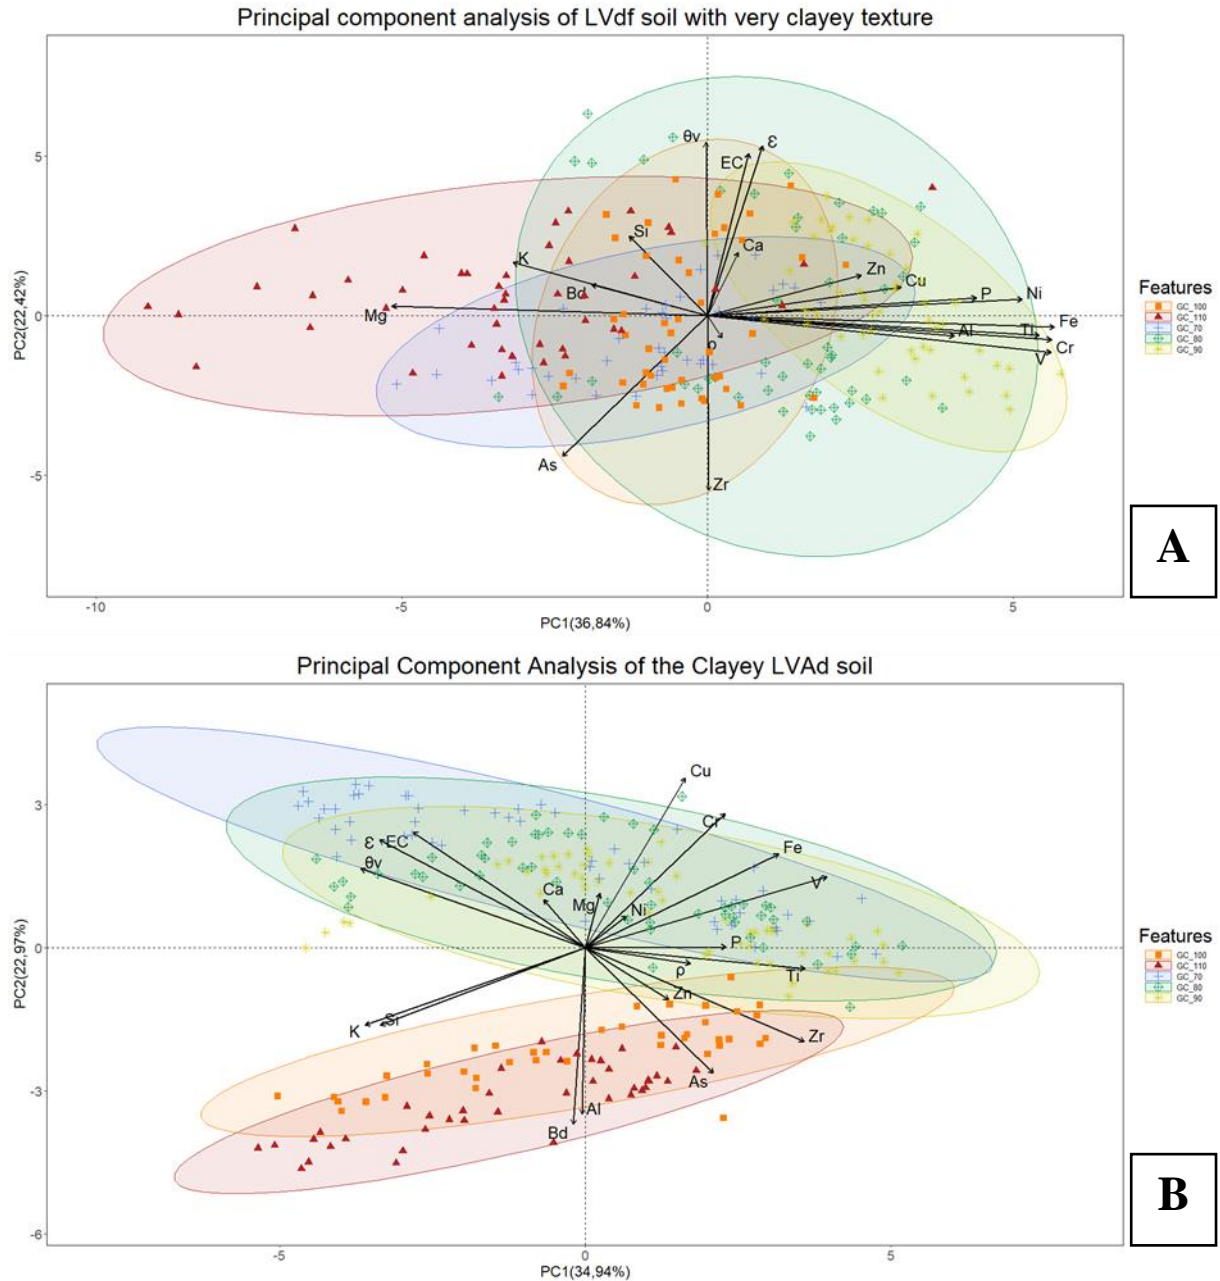


Fig 3. Principal Component Analysis (PCA) considering the following variables: soil water content (θ_v), electrical conductivity, electrical resistivity, apparent dielectric permittivity, chemical composition (content of Mg, Al, Si, P, K, Ca, Ti, V, Cr, Fe, Ni, Cu, Zn, As, Zr in percent) for different degrees of compaction in two oxisols, LVdf (A) and LVAd (B).

Analyzing the PCA of the LVAd soil order in Fig. 3 revealed a clearer distinction between the compaction degrees than LVdf. The first group includes samples with 70%, 80%, and 90% of DC, while the second group comprises those with 100% and 110% of DC. More compacted soils exhibit a stronger positive correlation with variables Al, Si, K, As, and Zr contents. Therefore, the higher levels of Si and Al in compacted soil can be explained by the

relative enrichment of these elements due to the rearrangement of particles causing reduction of pore spaces, compared to the solid part, which remains unchanged in volume and mass. This solid part is rich in Si and Al, which are mainly elements that constitute soil minerals (such as kaolinite and gibbsite in weathered soils). This is supported by (Ribeiro *et al.*, 2017), who found a strong positive correlation between bulk density and Si in undisturbed samples from various soils.

These correlations are crucial for the predictive models of pedotransfer functions for bulk density (Bd) and degree of compaction (DC). Since most of the sand and silt fractions are composed of SiO₂, it indicates that these soils are young and not highly weathered or leached (Martín-García *et al.*, 2023). This aligns with the pedotransfer models analyzed by (Reis *et al.*, 2024), considering models for Brazilian soils by (Tomasella e Hodnett, 1998), which show that an increase in bulk density or compaction is associated with higher sand and silt content. It suggests that higher Si content correlates with a greater degree of compaction.

3.2. Regression models with Random Forest

The outcomes for the different regression models adjusted for DC using Random Forest algorithm, taking into account the integration of the two soils (LVdf and LVAd), as independent, are shown in Table 3.

Table 3. Determination of Root mean square error, coefficient of determination and mean absolute error of the fitted models for the degree of compaction in Brazilian soils LVdf and LVAd using the random forest algorithm

Dataset	Models	Explanatory variables	N° of predictor variables	RMSE	R ²	MAE
LVAd + LVdf ¹	1	All variables	19	4.33	0.93	3.12
LVAd + LVdf ¹	2	All variables without θ_v	18	4.22	0.93	3.04
LVAd + LVdf ¹	3	pXRF with θ_v	16	4.61	0.91	3.34
LVAd + LVdf ¹	4	pXRF without θ_v	15	4.66	0.91	3.35

LVA _d + LVd ^{f1}	5	ML2x + TERSO12 + X5xtal 250 + θ_v	4	9.10	0.61	6.79
LVA _d + LVd ^{f1}	6	ML2x + TERSO12 + X5xtal 250	3	9.25	0.58	7.20
LVd ^{f2}	7	All variables	19	7.18	0.79	4.66
LVd ^{f2}	8	All variables without θ_v	18	7.17	0.78	4.60
LVd ^{f2}	9	pXRF with θ_v	16	7.23	0.78	4.61
LVd ^{f2}	10	pXRF without θ_v	15	7.27	0.78	4.65
LVd ^{f2}	11	ML2x + TERSO12 + X5xtal 250 + θ_v	4	8.67	0.68	5.91
LVd ^{f2}	12	ML2x + TERSO12 + X5xtal 250	3	10.35	0.54	7.55
LVA _d ³	13	All variables	19	6.35	0.79	4.40
LVA _d ³	14	All variables without θ_v	18	6.57	0.78	4.52
LVA _d ³	15	pXRF with θ_v	16	6.48	0.78	4.77
LVA _d ³	16	pXRF without θ_v	15	6.48	0.78	4.81
LVA _d ³	17	ML2x + TERSO12 + X5xtal 250 + θ_v	4	10.06	0.47	7.79
LVA _d ³	18	ML2x + TERSO12 + X5xtal 250	3	10.87	0.38	8.60

Source Note: Brazilian Soil Classification System (SiBCS) (Santos et al., 2018) and corresponding US Soil Taxonomy (Staff, 1998) classes; pXRF - portable X-ray fluorescence spectrometry; DL6 Soil Moisture Logger with ThetaProbe tipo ML2x, Resistivity Meter Model X5xtal 250 Power Multi-Point; TERSO 12 Advanced Soil Moisture Sensor, Temperature and EC; θ_v volumetric water content; 1 n=475, 2 n=230, 3n = 245

Taking into account all variables from both soil orders combined, an R^2 value of 0.929 was obtained. In other words, the Random Forest model explains 92.87% of the variability in soil compaction degree, indicating it is quite effective for predicting compaction. The RMSE of 4.33, being low, suggests that model predictions are close to the observed values, indicating a good model fit. With an MAE of 3.12, on average, there is not much difference between

predicted and observed values, indicating good model accuracy with low prediction errors. Removing θ_v , caused a slightly improve in R^2 value to 0.932. However, when considering individual soil orders without the θ_v , the R^2 value decreases (0.785 to 0.784) for LVdf and for LVAd (0.794 to 0.777), which still represent good explanatory power.

Models that take into account only the pXRF sensor variables with water content and without water content, R^2 values were 0.7790 and 0.7782 respectively for LVdf, with corresponding RMSE values of 7.2332 and 7.2653, and MAE values of 4.6065 and 4.6495. Similar results were observed for LVAd, with R^2 values of 0.7827 and 0.7816, RMSE values of 6.4812 and 6.4828, and MAE values of 4.7691 and 4.8113 respectively. Therefore, whether considering pXRF sensor variables with or without θ_v from saturated to dry, the prediction model remains robust, demonstrating a good overall fit to the data. The same occurred for taking in account all sensors and imply no need of measure θ_v as an additional entry variable in prediction models of DC, reducing expend time and cost in soil compaction diagnosis. These findings are different from previous literature, in which the accurate determination of elements is affected by θ_v (Kalnicky e Singhvi, 2001; Ribeiro *et al.*, 2017; Silva *et al.*, 2018; Stockmann, Uta *et al.*, 2016)

Already in the case that only the data from the electrical sensors with and without θ_v are taken into account, the predictive ability is reduced to a value of $R^2 = 0.684, 0.543$; RMSE = 8.67, 10.34; MAE = 5.91, 7.54 respectively for the LVdf soil. Similarly, for LVAd with and without θ_v has a $R^2 = 0.473, 0.384$; RMSE = 10.06, 10.87; MAE = 7.78, 8.60. Therefore, if only the electrical variables were taken into account with or without θ_v , the coefficient of determination R^2 has a low to moderate model performance with relatively high margin of error of RMSE and MAE. These findings suggest that θ_v affects more soil electric properties than pXRF variables when predicting DC. An additional test was done removing data from our database, remaining only one and dryer θ_v for modeling (table x supp. material). Result shown a moderate reduction in accuracy (R^2 to 0.75, 0.71 and 0.44; RMSE to 8.41, 8.95 and 11.11) for models with all variables (2), pXRF (4) and electric sensors (6) respectively and for both soil orders. Therefore, a suggestion to reduce the time and costs of predictions and not severely impact accuracy is dry the samples before modeling and use only pXRF. Seladji *et al.* (2010) also recommended in monitoring of soil compaction with ρ , to be done with soil in a dry state since ρ is sensitive to change in bulk density when water content is lower than 0.25 g g^{-1} .




Fig. 4. Estimation of variable importance in the best prediction model (*pXRF + ML2x + TEROS12 + X5xtal 250 + θv* data), using the metric of Percentage Increase in Mean Squared Error (%IncMSE) for degree of compaction prediction models with Random Forest algorithm: (A) integrating two soil orders LVdf + LVAd; (B) LVdf (Anionic Acrudox); (C) LVAd (Typic Hapludox).

The Percentage of Increase in the Mean Square Error (%IncMSE) was taken into account for the two soil orders in an integrated manner and separately in Fig 4 for the best DC prediction model. This metric is widely recognized by many authors to estimate the importance or weight of the variables in Random Forest Prediction models (González, Herrera e García, 2015; Grömping, 2009). In the case of the integrated form of the two soils LVdf + LVAd it could be observed that the variables that have more weight as a function of the (%IncMSE) are Si (25.875), Al (23.085), Cu (23.078), K (19.904), As (17.276), Ti (16.832) and Ca (16.194). On the other hand, if only the LVdf soil was taken into account, the most important variables would be Si (30.749), Al (14.654), Cu (13.659), Ti (13.534), Fe (13.066), Ca (12.045), and ρ (10.514). Lastly, for LVAd, the most significant variables are Cu (24.454), Al (18.153), EC (16.904), Cr (14.792), Si (13.665), Ti (13.148), and ρ (12.539). These results confirms Si and Al importance as predictors for DC, and also highlighted Cu and Ti as other good predictor independent of soil order. Among soil electric properties, ρ was the best predictor, followed by EC. (Pentos, Pieczarka e Serwata, 2021) best results ($R^2 > 0.7$) occurs for 0-0.5 and 0.4-0.5 m depth using EC measured at 0.5 and 1.0 m in-field contrasting with 0.1-0.2 m ($R^2 = 0.471$).

3.3. Classification Models with Random Forest

For predicting the degrees of compaction, the response variable was categorized into 5 classes (70%, 80%, 90%, 100%, and 110%). Predictor variables included chemical elements contents (Mg, Al, Si, P, K, Ca, Ti, V, Cr, Fe, Ni, Cu, Zn, As, Zr) measured by the pXRF sensor in percentage, ρ from the X5xtal 250 sensor, EC from the TEROS12 sensor, ε from the ML2x, and θ_v calculated using the standard oven-drying method.

Table 4. Overall accuracy and Kappa coefficient values of the fitted models for the degree of compaction classes (70%, 80%, 90%, 100%, and 110%) prediction of two oxisols (LVdf and LVAd) using the random forest algorithm

Dataset	Models	Explanatory variables	N° of predictor variables	Overall Accuracy	Kappa index
LVAd + LVdf ¹	1	All variables	19	0.92	0.89
LVAd + LVdf ¹	2	All variables without θ_v	18	0.93	0.91
LVAd + LVdf ¹	3	pXRF with θ_v	16	0.87	0.84
LVAd + LVdf ¹	4	pXRF without θ_v	15	0.87	0.84
LVAd + LVdf ¹	5	ML2x + TEROS12 + X5xtal 250 + θ_v	4	0.60	0.50
LVAd + LVdf ¹	6	ML2x + TEROS12 + X5xtal 250	3	0.55	0.43
LVdf ²	7	All variables	19	0.89	0.86
LVdf ²	8	All variables without θ_v	18	0.87	0.84
LVdf ²	9	pXRF with θ_v	16	0.83	0.78
LVdf ²	10	pXRF without θ_v	15	0.85	0.81
LVdf ²	11	ML2x + TEROS12 + X5xtal 250 + θ_v	4	0.65	0.56
LVdf ²	12	ML2x + TEROS12 + X5xtal 250	3	0.52	0.40
LVAd ³	13	All variables	19	0.80	0.74

LVAd ³	14	All variables without θ_v	18	0.80	0.74
LVAd ³	15	pXRF with θ_v	16	0.69	0.61
LVAd ³	16	pXRF without θ_v	15	0.69	0.61
LVAd ³	17	ML2x + TEROS12 + X5xtal 250 + θ_v	4	0.43	0.29
LVAd ³	18	ML2x + TEROS12 + X5xtal 250	3	0.39	0.23

LVdf - Anionic Acrudox; *LVAd* - Typic Hapludox; *pXRF* - portable X-ray fluorescence spectrometry; *ML2x* - apparent dielectric constant sensor; *X5xtal 250* - soil electrical resistivity sensor; *TEROS 12* - soil electrical conductivity sensor; θ_v - volumetric soil water content
 1 n = 475, 2 n = 230, 3 n = 245

According to the metrics of overall accuracy and Kappa coefficient, it was observed that the best prediction models for DC classes involve combining all variables across both soil orders without θ_v variable inclusion (accuracy = 0.93 kappa = 0.91). Accurate results predicting soil compaction using classification machine learning algorithm was previously reported by (Peixoto *et al.*, 2022), founding that Random Forest - like used here - and Classification and Regression Trees were more accurate (accuracy = 0.90, Kappa index = 0.76) than Artificial Neural Network and Support Vector Machine. In addition, these good accuracy models generated demonstrates the potential of sensors fusion combined with decision tree algorithm in identify classes of soil compaction that could severely impact crop production, since DC values more than 90% usually are critical for crop development (Carter, 1990; Domżał, Gliński e Lipiec, 1991; Håkansson, 1990; Lipiec *et al.*, 1991) as well as for macroporosity and hydraulic conductivity compromising whole hydrological cycle increasing erosion and reding water infiltration (Reichert *et al.*, 2009).

Contrasting sensors, the pXRF shows better model accuracy (overall accuracy > 0.68; Kappa coefficient > 0.60) than soil electric properties sensors (overall accuracy > 0.38 Kappa coefficient > 0.22). This indicates that predicting soil compaction is still feasible based solely on soil elemental composition. However, models using electrical sensors did not achieve good accuracy due to measuring only one or two variables. Unlike the pXRF sensor, which captures a wide range of chemical elements becoming 15 explanatory variables in this study. In addition, as same as observed in table 3 for regression models, accuracy improves with more samples (combining the two soils data) and slightly change with or without inclusion of θ_v as an explanatory variable. Individual models for soil orders perform overall accuracy > 0.8, but LVdf soil has slightly better quality of models than LVAd.




Fig 5. Determination of the relevance of variables in the prediction model (portable X-ray fluorescence pXRF + ML2x + TEROS12 + X5xtal 250 + θv), integrating two soil orders LVdf and LVAd. The metrics Mean Decrease Accuracy and Mean Decrease Gini were used to assess compaction degrees (70%, 80%, 90%, 100%, and 110%) using Random Forest algorithms without data preprocessing.

Considering the Mean Decrease Accuracy, the most important variables for the model integrating both soils (LVdf and LVAd) are: Al (38.0), Cu (28.9), EC (28.8), Si (28.0), K (25.9), and Fe (25.6). Looking at specific values of relevance for each degree of compaction, there was no clear pattern. For instance, although Al is the most important variable in terms of overall accuracy and impurity reduction, it does not correlate to specific DC relevance values. Conversely, the importance of Si (23.6), EC (27.6), Electrical Resistivity (13.9), and Volumetric Water Content (9.72) is much higher in uncompact soil (DC 70%) compared to compacted soil with Si (DC 100 = 15.05, DC 110 = 15.17), EC (DC 100 = 9.9, DC 110 = 10.7), Electrical Resistivity (DC 100 = 5.23, DC 110 = 8.0), Volumetric Water Content (DC100 = 7.32, DC 110 = 6.36).

Table 5. Confusion matrix and balanced accuracy obtained from the best prediction model at different degree compaction (DC_110, DC_100, DC_90, DC_80, DC_70) for the combined prediction of both soils (LVdf and LVAd) provided by the Random Forest classification model

From/To	DC_100%	DC_110%	DC_70%	DC_80%	DC_90%	Balanced accuracy
DC_100%	16	1	0	0	0	0.96

DC_110%	0	18	0	0	0	0.95
DC_70%	0	0	14	0	0	0.97
DC_80%	0	0	1	19	2	0.93
DC_90%	1	1	0	2	20	0.93

DC_100 – 100% degree of compaction; DC_110 – 110% degree of compaction; DC_70 – 70% degree of compaction; DC_80 – 80% degree of compaction; DC_90 – 90% degree of compaction; LVdf - Anionic Acrudox; LVAd - Typic Hapludox.

On the other hand, in low DC condition (DC 70), the importance of variables such as Cu (11.8), Fe (6.8), Zn (3.7), As (9.3), and V (5.8) is much lower compared to highly compacted soils: Cu (DC 110 = 21.29), Fe (DC 110 = 16.6), Zn (DC 110 = 15.56), As (DC 110 = 14.0), and V (DC 110 = 10.16).

Considering the confusion matrix for both soils (LVdf and LVAd) and integrating all variables from proximal sensors and water content using the RF algorithm (Table 5), high model performance was achieved for each compaction class, with accuracy exceeding 90%.

Classification models LVdf

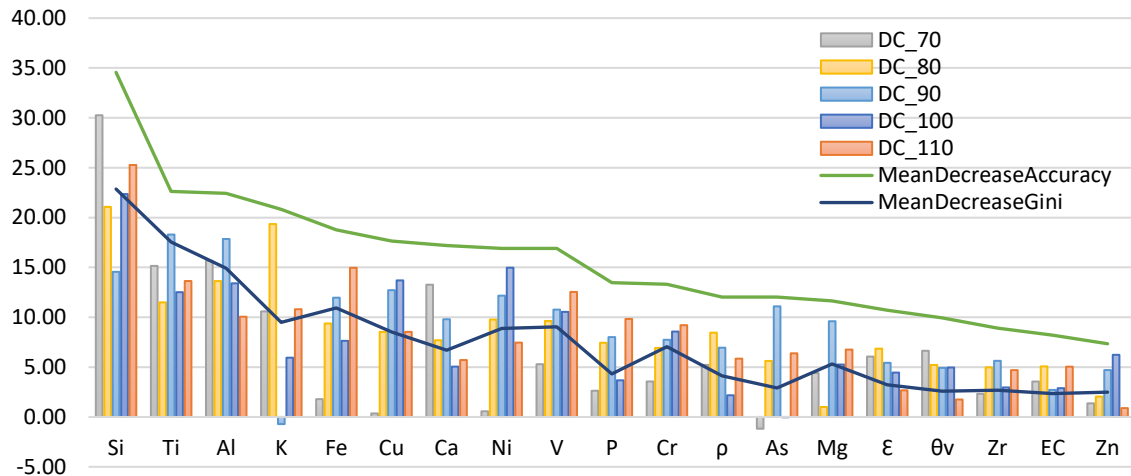


Fig 6. Relevance of explanatory variables in the prediction model using all sensors and soil water content ($pXRF + ML2x + TERS12 + X5xtal\ 250 + \theta v$) for degree of compactness classes (70%, 80%, 90%, 100%, and 110%) for LVdf (Anionic acrudox) using Random Forest algorithms. Green line represents Mean Decrease Accuracy and blue line represents Mean Decrease Gini.

Considering the Mean Decrease Accuracy for the LVdf soil order, the most important variables for the model are Si, Ti, Al, K, and Fe. Removing any of these variables would reduce

the overall accuracy of the model by 34.5 (Si), 22.6 (Ti), 22.4 (Al), 20.8 (K), and 18.77 (Fe) respectively.

Table 6. Confusion matrix and balanced accuracy obtained from the best prediction model at different degree compaction (DC_110, DC_100, DC_90, DC_80, DC_70) for soil (LVdf) prediction provided by the Random Forest classification model.

From/To	DC_100%	DC_110%	DC_70%	DC_80%	DC_90%	Balanced accuracy
DC_100%	8	1	0	0	0	0.94
DC_110%	1	8	0	0	0	0.93
DC_70%	0	0	9	0	0	0.95
DC_80%	0	0	1	6	1	0.90
DC_90%	0	1	0	1	10	0.93

DC_100 – 100% degree of compaction; DC_110 – 110% degree of compaction; DC_70 – 70% degree of compaction; DC_80 – 80% degree of compaction; DC_90 – 90% degree of compaction; LVdf - Anionic Acrudox.

Analyzing the confusion matrix considering the soil (LVdf) by integrating all variables with the RF algorithm (Table 6), the model achieved high performance for each compaction class.




Fig 7. Relevance of explanatory variables in the prediction model using all sensors and soil water content (pXRF + ML2x + TEROS12 + X5xtal 250 + θ_v) for degree of compactness classes (70%, 80%, 90%, 100%, and 110%) for LVAd (Typic hapludox) using Random Forest

algorithms. Green line represents Mean Decrease Accuracy and blue line represents Mean Decrease Gini.

For the LVAd soil order, considering the Mean Decrease Accuracy, the most crucial variables for the model are Cu (27.9), EC (24.5), Fe (22.1), Al (21.1), and Zn (19.5). Observing the specific values according to the DC, the importance of Cu increases as the DC rises (DC 70 = 13.53, DC 80 = 17.41, DC 90 = 20.68, DC 100 = 21.37, DC 110 = 21.63), while an opposite pattern occurs for the importance of EC, decreasing importance as the soil becomes more compacted (DC 70 = 24.9, DC 80 = 10.13, DC 90 = 10.09, DC 100 = 9.8, DC110 = 8.3).

Table 7. Confusion matrix and balanced accuracy obtained from the best prediction model at different degree compaction (DC_110, DC_100, DC_90, DC_80, DC_70) for soil (LVAd) prediction provided by the Random Forest classification model.

From/To	DC_100%	DC_110%	DC_70%	DC_80%	DC_90%	Balanced accuracy
DC_100%	4	1	2	0	0	0.97
DC_110%	0	9	0	0	0	0.95
DC_70%	0	0	8	0	0	0.83
DC_80%	0	0	1	11	3	0.87
DC_90%	0	0	1	2	7	0.81

DC_100 – 100% degree of compaction; DC_110 – 110% degree of compaction; DC_70 – 70% degree of compaction; DC_80 – 80% degree of compaction; DC_90 – 90% degree of compaction; LVAd - Typic Hapludox.

Considering the confusion matrix for the soil (LVAd) and integrating all variables with the RF algorithm (Table 7), high model performance was achieved for each compaction class, with a slight decrease in accuracy for the less compacted soil classes (DC_70=0.83, DC_80=0.87, and DC_90=0.81).

Summarizing the results in Figs 5, 6 and 7, the overall mean importance of the five most important or explanatory variables varied with soil type and when the two soils were combined. However, Al, Si and Cu were the best variables from the pXRF sensor, while conductivity and resistivity were the best from the electrical sensors. As suggest for regression modelling, to avoid unnecessary costs, only one sensor - pXRF (overall accuracy = 0.87 and Kappa index = 0.84) - provided best results for DC classification without inclusion of θ_v - which needs

sampling undisturbed soil and laboratory analyses - therefore becoming a promising strategy for accurate diagnosis of soil compaction.

4. Conclusions

- According to the results presented in this research, it was demonstrated that combining proximal sensors with the Random Forest algorithm yielded accurate prediction models for determining the degree of soil compaction both numerically and categorically confirming our hypothesis.
- For the LVdf (n=4600), the model yielded $R^2=0.79$; RMSE=7.18 and MAE=4.66. For the LVAd (n=4900), the model produced $R^2=0.79$; RMSE=6.35 and MAE=4.40. When integrated as LVdf+LVAd (n=9500), the model achieved $R^2=0.93$; RMSE=4.33; MAE=3.12, resulting in robust and accurate predictions. The LVdf model exhibited a better fit compared to LVAd, despite having a smaller sample size.
- Also was tested the inclusion of soil water content as an explanatory variable. Results shown tha prediction models did not significantly improve performance. However, it slightly altered the importance ranking of the variables, affecting Fe in LVdf and Si, Ti, Zn, and ρ in LVAd.
- Considering the differences among proximal sensors, the X-ray fluorescence sensor provided a better model fit to the data, with (R^2) values of 0.78 for LVdf both with and without (θ_v), 0.78 for LVAd both with and without (θ_v), and 0.91 for the combined LVdf+LVAd with and without (θ_v). These results were superior to those of the three combined electrical sensors (ρ , EC, ε), which had (R^2) values of 0.68-0.54 for LVdf with and without (θ_v), 0.47-0.38 for LVAd with and without (θ_v), and 0.61-0.58 for the combined LVdf+LVAd. This difference is likely due to the pXRF detecting most of the important variables and its ability to measure a wide range of chemical contents.
- Although the metrics performed well in the classification models, a defined distribution pattern based on the degree of compaction was not observed. However, we can state that for LVdf, the most important variables for DC 70 were Si and Al; for DC 80, Si and K; for DC 90, Ti, Fe, and Al; for DC 100, Si; and for DC 110, Si, Fe, Ti, V, K, and Al. Finally, for LVAd, the most important variables for DC 70 were EC and ε ; for DC 80, Cu and Al; for DC 90, Fe and Cu; for DC 100, Cu, Al, and Zn; and for DC 110, Cu, Cr, Zn, and Fe

- In summary, the models developed in this study can accurately predict soil compaction without moving the sensors along the crop surface. It is relevant to continue this study to expand the database to include soils from other regions. This would enable rapid prediction, cost reduction by considering only the most important variables specific to each soil characteristic, thus preserving the environment.

5. Recommendations

It is recommended to establish an optimum water content interval (depending on soil texture), in which an accurate estimation of soil bulk density can be ensured.

It was observed that in Typic Hapludox with a clayey texture and without compaction, certain variables such as Zr content, water content, electrical conductivity, and dielectric constant showed greater data dispersion, variability, and interquartile range. However, as the soil became compacted, there was a slight increase in the variability of Si and K content.

It is recommended to slightly increase the height of the cylinders, as the needles of the dielectric constant sensors were close to touching the bottom of the compacted samples.

6. Acknowledgments

We acknowledge the financial contribution of Coordination for the Improvement of Higher Education Personnel (CAPES), for support and infrastructure and National Council for Scientific and Technological Development (CNPq) and Foundation for Research Support of the State of Minas Gerais (FAPEMIG), and Department of Soil Science at Federal University of Lavras (DCS – UFLA). The authors are also thankful to support provided by Dr. Renata Andrade, Samara Martins Barbosa and Paulo Gherardi Hein.

7. References

- Al-Asadi, R.A., Mouazen, A.M., 2014a. Combining frequency domain reflectometry and visible and near infrared spectroscopy for assessment of soil bulk density. *Soil Tillage Res* 135, 60–70. <https://doi.org/10.1016/J.STILL.2013.09.002>
- Al-Asadi, R.A., Mouazen, A.M., 2014b. Combining frequency domain reflectometry and visible and near infrared spectroscopy for assessment of soil bulk density. *Soil Tillage Res* 135, 60–70. <https://doi.org/10.1016/J.STILL.2013.09.002>

- 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, 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Andrade, R., Mancini, M., Teixeira, A.F. dos S., Silva, S.H.G., Weindorf, D.C., Chakraborty, S., Guilherme, L.R.G., Curi, N., 2022. Proximal sensor data fusion and auxiliary information for tropical soil property prediction: Soil texture. *Geoderma* 422, 115936. <https://doi.org/10.1016/J.GEODERMA.2022.115936>
- Andrade, R., Silva, S.H.G., Weindorf, D.C., Chakraborty, S., Faria, W.M., Guilherme, L.R.G., Curi, N., 2020a. Tropical soil order and suborder prediction combining optical and X-ray approaches. *Geoderma Regional* 23, e00331. <https://doi.org/10.1016/J.GEODRS.2020.E00331>
- Andrade, R., Silva, S.H.G., Weindorf, D.C., Chakraborty, S., Faria, W.M., Mesquita, L.F., Guilherme, L.R.G., Curi, N., 2020b. Assessing models for prediction of some soil chemical properties from portable X-ray fluorescence (pXRF) spectrometry data in Brazilian Coastal Plains. *Geoderma* 357, 113957. <https://doi.org/10.1016/J.GEODERMA.2019.113957>
- Arvidsson, J., Håkansson, I., 2014. Response of different crops to soil compaction—Short-term effects in Swedish field experiments. *Soil Tillage Res* 138, 56–63. <https://doi.org/10.1016/J.STILL.2013.12.006>
- Bengough, A.G., Bransby, M.F., Hans, J., Mckenna, S.J., Roberts, T.J., Valentine, T.A., 2011. Root responses to soil physical conditions; growth dynamics from field to cell. *J Exp Bot* 62, 59–68. <https://doi.org/10.1093/jxb/erj003>
- Bertermann, D., Schwarz, H., 2017. Laboratory device to analyse the impact of soil properties on electrical and thermal conductivity. *Int Agrophys* 31, 157–166. <https://doi.org/10.1515/intag-2016-0048>
- Besson, A., Cousin, I., Samouëlian, A., Boizard, H., Richard, G., 2004. Structural heterogeneity of the soil tilled layer as characterized by 2D electrical resistivity surveying. *Soil Tillage Res* 79, 239–249. <https://doi.org/10.1016/J.STILL.2004.07.012>
- Bittelli, M., Tomei, F., Anbazhagan, P., Pallapati, R.R., Mahajan, P., Meisina, C., Bordoni, M., Valentino, R., 2021. Measurement of soil bulk density and water content with time domain reflectometry: Algorithm implementation and method analysis. *J Hydrol (Amst)* 598, 126389. <https://doi.org/10.1016/J.JHYDROL.2021.126389>

- Brillante, L., Mathieu, O., Bois, B., van Leeuwen, C., Lévêque, J., 2015. The use of soil electrical resistivity to monitor plant and soil water relationships in vineyards. *SOIL* 1, 273–286. <https://doi.org/10.5194/soil-1-273-2015>
- Carter, M.R., 1990. Relative measures of soil bulk density to characterize compaction in tillage studies on fine sandy loams. *Can J Soil Sci* 70, 425–433.
- Cean, R., Mancini, M., Silva, S.H.G., Bakr, N., Chakraborty, S., Li, B., Acree, A., Anjos, L.H.C. dos, Curi, N., Weindorf, D.C., 2024. Proximal sensor characterization of Haitian agricultural soils: A case study in the Central Plateau. *J South Am Earth Sci* 143, 105007. <https://doi.org/10.1016/J.JSAMES.2024.105007>
- Cho, Y., Sudduth, K.A., Chung, S.O., 2016. Soil physical property estimation from soil strength and apparent electrical conductivity sensor data. *Biosyst Eng* 152, 68–78. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2016.07.003>
- Cohen, J., 1960. A Coefficient of Agreement for Nominal Scales. *Educ Psychol Meas* 20, 37–46. <https://doi.org/10.1177/001316446002000104>
- Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens Environ* 37, 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Curi, N., Silva, S., Poggere, G., Duarte de Menezes, M., 2017. MAPEAMENTO DE SOLOS E MAGNETISMO NO CAMPUS DA UFLA COMO TRAÇADORES AMBIENTAIS.
- Curioni, G., Chapman, D.N., Pring, L.J., Royal, A.C.D., Metje, N., 2018. Extending TDR capability for measuring soil density and water content for field condition monitoring. *Journal of Geotechnical and Geoenvironmental Engineering* 144, 04017111.
- de Cássia Goulart Ferreira, Q., de Almeida Prado Bacellar, L., Moreira Viana, J.H., 2021. Evaluation of soil moisture by electrical resistivity in Oxisols of the central Brazilian savanna. *Geoderma Regional* 26, e00408. <https://doi.org/10.1016/J.GEODRS.2021.E00408>
- de Moraes, F.A., Moreira, S.G., Peixoto, D.S., Resende Silva, J.C., Macedo, J.R., Silva, M.M., Silva, B.M., Sanchez, P.A., Nunes, M.R., 2023. Lime incorporation up to 40 cm deep increases root growth and crop yield in highly weathered tropical soils. *European Journal of Agronomy* 144, 126763. <https://doi.org/10.1016/J.EJA.2023.126763>
- DELTA-T DEVICES. ThetaProbe soil moisture sensor - ML2x: user manual. Cambridge: Delta-T Devices, 1999.
- Dias Junior, M. de S., Martins, P.C.C., 2017. Ensaio de compressão uniaxial e modelos de capacidade de suporte de carga do solo. *Manual de métodos de análise de solo* 3, 152–171.

- Domżał, H., Gliński, J., Lipiec, J., 1991. Soil compaction research in Poland. *Soil Tillage Res* 19, 99–109. [https://doi.org/10.1016/0167-1987\(91\)90079-D](https://doi.org/10.1016/0167-1987(91)90079-D)
- Fragkos, A., Loukatos, D., Kargas, G., Arvanitis, K., 2024. Response of the TEROS 12 Soil Moisture Sensor under Different Soils and Variable Electrical Conductivity. *Sensors* 24, 2206. <https://doi.org/10.3390/s24072206>
- González, S., Herrera, F., García, S., 2015. Monotonic Random Forest with an Ensemble Pruning Mechanism based on the Degree of Monotonicity. *New Gener Comput* 33, 367–388. <https://doi.org/10.1007/s00354-015-0402-4>
- Graves, A.R., Morris, J., Deeks, L.K., Rickson, R.J., Kibblewhite, M.G., Harris, J.A., Farewell, T.S., Truckle, I., 2015. The total costs of soil degradation in England and Wales. *Ecological Economics* 119, 399–413. <https://doi.org/10.1016/J.ECOLECON.2015.07.026>
- Grömping, U., 2009. Variable importance assessment in regression: linear regression versus random forest. *Am Stat* 63, 308–319.
- Hadzick, Z.Z., Guber, A.K., Pachepsky, Y.A., Hill, R.L., 2011. Pedotransfer functions in soil electrical resistivity estimation. *Geoderma* 164, 195–202. <https://doi.org/10.1016/J.GEODERMA.2011.06.004>
- Håkansson, I., 1990. A method for characterizing the state of compactness of the plough layer. *Soil Tillage Res* 16, 105–120. [https://doi.org/10.1016/0167-1987\(90\)90024-8](https://doi.org/10.1016/0167-1987(90)90024-8)
- Hamza, M.A., Anderson, W.K., 2005. Soil compaction in cropping systems: A review of the nature, causes and possible solutions. *Soil Tillage Res* 82, 121–145. <https://doi.org/10.1016/J.STILL.2004.08.009>
- Islam, M.M., Saey, T., De Smedt, P., Van De Vijver, E., Delefortrie, S., Meirvenne, M., 2014. Modeling within field variation of the compaction layer in a paddy rice field using a proximal soil sensing system. *Soil Use Manag* 30. <https://doi.org/10.1111/sum.12098>
- Jeřábek, J., Zumr, D., Dostál, T., 2017. Identifying the plough pan position on cultivated soils by measurements of electrical resistivity and penetration resistance. *Soil Tillage Res* 174, 231–240. <https://doi.org/10.1016/J.STILL.2017.07.008>
- Jung, S., Drnevich, V.P., Abou Najm, M.R., 2013. New methodology for density and water content by time domain reflectometry. *Journal of Geotechnical and Geoenvironmental Engineering* 139, 659–670.
- Kalnicky, D.J., Singhvi, R., 2001. Field portable XRF analysis of environmental samples. *J Hazard Mater* 83, 93–122. [https://doi.org/10.1016/S0304-3894\(00\)00330-7](https://doi.org/10.1016/S0304-3894(00)00330-7)

- Kämpf, N., Marques, J.J., Curi, N., 2012. Mineralogia de solos brasileiros In: KER, JC; CURI, N.; SCHAEFER, CEGR; VIDAL-TORRADO, P. Pedologia: fundamentos. Viçosa, MG: SBCS 81–146.
- Keller, T., Colombi, T., Ruiz, S., Pogs, M., Rek, J., Stadelmann, V., Wunderli, H., Breitenstein, D., Reiser, R., Oberholzer, H., 2017. Long-Term Soil Structure Observatory for Monitoring Post-Compaction Evolution of Soil Structure. *Vadose Zo. J.* 16, 1–16.
- Keller, T., Sandin, M., Colombi, T., Horn, R., Or, D., 2019. Historical increase in agricultural machinery weights enhanced soil stress levels and adversely affected soil functioning. *Soil Tillage Res* 194, 104293. <https://doi.org/10.1016/J.STILL.2019.104293>
- Kowalczyk, S., Maślakowski, M., Tucholka, P., 2014. Determination of the correlation between the electrical resistivity of non-cohesive soils and the degree of compaction. *J Appl Geophy* 110, 43–50. <https://doi.org/10.1016/J.JAPPGEO.2014.08.016>
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., Mayer, Z., Kenkel, B., Team, R.C., 2020. Package ‘caret.’ *R J* 223, 48.
- Laiho, J.V.-P., Perämäki, P., 2005. Evaluation of portable X-ray fluorescence (PXRF) sample preparation methods. *Special Paper of the Geological Survey of Finland* 73–82.
- Landis, J.R., Koch, G.G., 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics* 33, 159–174. <https://doi.org/10.2307/2529310>
- Lipiec, J., Håkansson, I., Tarkiewicz, S., Kossowski, J., 1991. Soil physical properties and growth of spring barley as related to the degree of compactness of two soils. *Soil Tillage Res* 19, 307–317. [https://doi.org/10.1016/0167-1987\(91\)90098-I](https://doi.org/10.1016/0167-1987(91)90098-I)
- Lipiec, J., Horn, R., Pietrusiewicz, J., Siczek, A., 2012. Effects of soil compaction on root elongation and anatomy of different cereal plant species. *Soil Tillage Res* 121, 74–81. <https://doi.org/10.1016/J.STILL.2012.01.013>
- Loke, M.H., 1999. Electrical imaging surveys for environmental and engineering studies. *A practical guide to* 2, 70.
- LTD, D.-T.D., 1995. ThetaProbe soil moisture sensor type ML1, user manual.
- Macák, M., Rataj, V., Barát, M., Kosiba, J., Galambošová, J., 2019. DETERMINING SOIL COMPACTION AT TRAFFIC LINES WITH PROXIMAL SOIL SENSING.
- Malehmir, A., Socco, L. V., Bastani, M., Krawczyk, C.M., Pfaffhuber, A.A., Miller, R.D., Maurer, H., Frauenfelder, R., Suto, K., Bazin, S., Merz, K., Dahlin, T., 2016. Near-Surface Geophysical Characterization of Areas Prone to Natural Hazards: A Review of the Current and Perspective on the Future. *Advances in Geophysics* 57, 51–146. <https://doi.org/10.1016/BS.AGPH.2016.08.001>

- Martín-García, M., Delgado, R., Calero, J., Henrique, S., Silva, G., Ribeiro, D., Santos, T., Dijair, B., Silva, F.M., Fernanda, A., Teixeira, S., Andrade, R., Mancini, M., Roberto, L., Guilherme, G., Curi, N., 2023. Different Quartz Varieties Characterized by Proximal Sensing and Their Relation to Soil Attributes. <https://doi.org/10.3390/min13040529>
- Maruyama, Y., Ogawa, K., Okada, T., Kato, M., 2008. Laboratory experiments of particle size effect in X-ray fluorescence and implications to remote X-ray spectrometry of lunar regolith surface. *Earth, planets and space* 60, 293–297.
- Melo, L.B.B. de, Silva, B.M., Peixoto, D.S., Chiarini, T.P.A., de Oliveira, G.C., Curi, N., 2021. Effect of compaction on the relationship between electrical resistivity and soil water content in Oxisol. *Soil Tillage Res* 208, 104876. <https://doi.org/10.1016/J.STILL.2020.104876>
- Meter, 2018. User guide for TERSOS 11/12. Available online: http://publications.metergroup.com/Manuals/20587_TEROS11-12_Manual_Web.pdf (accessed on 20 May 2024).
- Michot, D., Benderitter, Y., Dorigny, A., Nicoullaud, B., King, D., Tabbagh, A., 2003. Spatial and temporal monitoring of soil water content with an irrigated corn crop cover using surface electrical resistivity tomography. *Water Resour Res* 39. <https://doi.org/10.1029/2002WR001581>
- Minasny, B., Hartemink, A.E., 2011. Predicting soil properties in the tropics. *Earth Sci Rev* 106, 52–62. <https://doi.org/10.1016/J.EARSCIREV.2011.01.005>
- Naderi-Boldaji, M., Tekeste, M.Z., Nordstorm, R.A., Barnard, D.J., Birrel, S.J., 2019. A mechanical-dielectric-high frequency acoustic sensor fusion for soil physical characterization. *Comput Electron Agric* 156, 10–23. <https://doi.org/10.1016/J.COMPAG.2018.11.006>
- Or, D., Keller, T., Schlesinger, W.H., 2021. Natural and managed soil structure: On the fragile scaffolding for soil functioning. *Soil Tillage Res* 208, 104912. <https://doi.org/10.1016/J.STILL.2020.104912>
- Peixoto, D., Silva, S., Moreira, S., Alvarenga Pereira da Silva, A., Chiarini, T., da Silva, L., Curi, N., Silva, B., 2022. Machine learning as a useful tool for diagnosis of soil compaction under continuous no-tillage in Brazil. *Soil Research* 61. <https://doi.org/10.1071/SR22048>
- Peixoto, D.S., Silva, B.M., de Oliveira, G.C., Moreira, S.G., da Silva, F., Curi, N., 2019. A soil compaction diagnosis method for occasional tillage recommendation under continuous

- no tillage system in Brazil. *Soil Tillage Res* 194, 104307. <https://doi.org/10.1016/J.STILL.2019.104307>
- Peixoto, D.S., Silva, L. de C.M. da, Melo, L.B.B. de, Azevedo, R.P., Araújo, B.C.L., Carvalho, T.S. de, Moreira, S.G., Curi, N., Silva, B.M., 2020. Occasional tillage in no-tillage systems: A global meta-analysis. *Science of The Total Environment* 745, 140887. <https://doi.org/10.1016/J.SCITOTENV.2020.140887>
- Pentos, K., Pieczarka, K., Serwata, K., 2021. The Relationship between Soil Electrical Parameters and Compaction of Sandy Clay Loam Soil. <https://doi.org/10.3390/agriculture11020114>
- Quraishi, M.Z., Mouazen, A.M., 2013. A prototype sensor for the assessment of soil bulk density. *Soil Tillage Res* 134, 97–110. <https://doi.org/10.1016/J.STILL.2013.07.011>
- Reichert, J.M., Suzuki, L.E.A.S., Reinert, D.J., Horn, R., Håkansson, I., 2009. Reference bulk density and critical degree-of-compactness for no-till crop production in subtropical highly weathered soils. *Soil Tillage Res* 102, 242–254. <https://doi.org/10.1016/J.STILL.2008.07.002>
- Reis, A.M.H. dos, Teixeira, W.G., Fontana, A., Barros, A.H.C., Victoria, D. de C., Vasques, G.M., Samuel-Rosa, A., Ottoni, M.V., Monteiro, J.E.B. de A., 2024. Hierarchical pedotransfer functions for predicting bulk density in Brazilian soils. *Sci Agric* 81, e20220255. <https://doi.org/10.1590/1678-992x-2022-0255>
- Rhoades, J., Corwin, D., Lesch, S., 1999. Geospatial Measurements of Soil Electrical Conductivity to Determine Soil Salinity and Diffuse Salt Loading from Irrigation, in: *Geophysical Monograph Series*. pp. 197–215. <https://doi.org/10.1029/GM108p0197>
- Ribeiro, B.T., Silva, S.H.G., Silva, E.A., Guilherme, L.R.G., 2017. Portable X-ray fluorescence (pXRF) applications in tropical Soil Science. *Ciência e Agrotecnologia* 41, 245–254. <https://doi.org/10.1590/1413-70542017413000117>
- Romero-Ruiz, A., Linde, N., Keller, T., Or, D., 2018. A Review of Geophysical Methods for Soil Structure Characterization. *Reviews of Geophysics* 56, 672–697. <https://doi.org/10.1029/2018RG000611>
- Samouëlian, A., Cousin, I., Tabbagh, A., Bruand, A., Richard, G., 2005. Electrical resistivity survey in soil science: a review. *Soil Tillage Res* 83, 173–193. <https://doi.org/10.1016/J.STILL.2004.10.004>
- Santana, M.L.T., dos Santos, F.F., de Carvalho, K.M., Peixoto, D.S., Uezu, A., Avanzi, J.C., Serafim, M.E., Nunes, M.R., van Es, H.M., Curi, N., Silva, B.M., 2023. Interactions between land use and soil type drive soil functions, highlighting water recharge

- potential, in the Cantareira System, Southeast of Brazil. *Science of The Total Environment* 903, 166125. <https://doi.org/10.1016/J.SCITOTENV.2023.166125>
- Santos, H.G., JACOMINE, P.K.T., Dos Anjos, L.H.C., De Oliveira, V.A., LUMBRERAS, J.F., COELHO, M.R., De Almeida, J.A., de Araujo Filho, J.C., de OLIVEIRA, J.B. de, CUNHA, T.J.F., 2018. Sistema brasileiro de classificação de solos. Brasília, DF: Embrapa, 2018.
- Seladji, S., Cosenza, P., Tabbagh, A., Ranger, J., Richard, G., 2010. The effect of compaction on soil electrical resistivity: a laboratory investigation. *Eur J Soil Sci* 61, 1043–1055. <https://doi.org/10.1111/j.1365-2389.2010.01309.x>
- Silva, B.M., Oliveira, G.C. de, Serafim, M.E., Silva Júnior, J.J. da, Colombo, A., Lima, J.M. de, 2012. Acurácia e calibração de sonda de capacitância em Latossolo Vermelho cultivado com cafeeiro. *Pesqui Agropecu Bras* 47, 277–286. <https://doi.org/10.1590/S0100-204X2012000200017>
- Silva, L. de C.M. da, Peixoto, D.S., Azevedo, R.P., Avanzi, J.C., Dias Junior, M. de S., Vanella, D., Consoli, S., Acuña-Guzman, S.F., Borghi, E., Resende, Á.V. de, Silva, B.M., 2023. Assessment of soil water content variability using electrical resistivity imaging in an Oxisol under conservation cropping systems. *Geoderma Regional* 33, e00624. <https://doi.org/10.1016/J.GEODRS.2023.E00624>
- Silva, S.H.G., Silva, E.A., Poggere, G.C., Guilherme, L.R.G., Curi, N., 2018. Tropical soils characterization at low cost and time using portable X-ray fluorescence spectrometer (pXRF): Effects of different sample preparation methods. *Ciência e Agrotecnologia* 42, 80–92. <https://doi.org/10.1590/1413-70542018421009117>
- Staff, S.S., 1998. Keys to Soil Taxonomy, United States Department of Agriculture. Natural Resources Conservation Service, Washington, DC.
- Stockmann, U., Cattle, S.R., Minasny, B., McBratney, A.B., 2016. Utilizing portable X-ray fluorescence spectrometry for in-field investigation of pedogenesis. *Catena (Amst)* 139, 220–231. <https://doi.org/10.1016/J.CATENA.2016.01.007>
- Stockmann, Uta, Jang, H.J., Minasny, B., McBratney, A.B., 2016. The Effect of Soil Moisture and Texture on Fe Concentration Using Portable X-Ray Fluorescence Spectrometers. pp. 63–71. https://doi.org/10.1007/978-3-319-28295-4_5
- Sudduth, K.A., Drummond, S.T., Kitchen, N.R., 2001. Accuracy issues in electromagnetic induction sensing of soil electrical conductivity for precision agriculture. *Comput Electron Agric* 31, 239–264. [https://doi.org/10.1016/S0168-1699\(00\)00185-X](https://doi.org/10.1016/S0168-1699(00)00185-X)

- Szatanik-Kloc, A., Horn, R., Lipiec, J., Siczek, A., Szerement, J., 2018. Soil compaction-induced changes of physicochemical properties of cereal roots. *Soil Tillage Res* 175, 226–233. <https://doi.org/10.1016/J.STILL.2017.08.016>
- Taiwo, S., Jong-Sub, L., Hyung-Koo, Y., 2017. Analytical and experimental studies to obtain electrical resistivity in a small-scaled laboratory test. *GEOPHYSICS* 82, 1–33. <https://doi.org/10.1190/geo2016-0491.1>
- Team, R.C., 2021. A language and environment for statistical computing. (No Title).
- Teixeira, A.F. dos S., Andrade, R., Mancini, M., Silva, S.H.G., Weindorf, D.C., Chakraborty, S., Guilherme, L.R.G., Curi, N., 2022. Proximal sensor data fusion for tropical soil property prediction: Soil fertility properties. *J South Am Earth Sci* 116, 103873. <https://doi.org/10.1016/J.JSAMES.2022.103873>
- Tian, Z., Ren, T., Horton, R., Heitman, J.L., 2020. Estimating soil bulk density with combined commercial soil water content and thermal property sensors. *Soil Tillage Res* 196, 104445. <https://doi.org/10.1016/J.STILL.2019.104445>
- Tomasella, J., Hodnett, M.G., 1998. Estimating soil water retention characteristics from limited data in brazilian amazonia. *Soil Sci* 163.
- Vingiani, S., Buttafuoco, G., Fagnano, M., Guarino, A., Perreca, C., Albanese, S., 2024. A multisensor approach coupled with multivariate statistics and geostatistics for assessing the status of land degradation: The case of soils contaminated in a former outdoor shooting range. *Science of The Total Environment* 933, 172398. <https://doi.org/10.1016/J.SCITOTENV.2024.172398>
- Weindorf, D.C., Bakr, N., Zhu, Y., 2014. Advances in Portable X-ray Fluorescence (PXRF) for Environmental, Pedological, and Agronomic Applications. *Advances in Agronomy* 128, 1–45. <https://doi.org/10.1016/B978-0-12-802139-2.00001-9>

8. Appendix A – Supplementary material

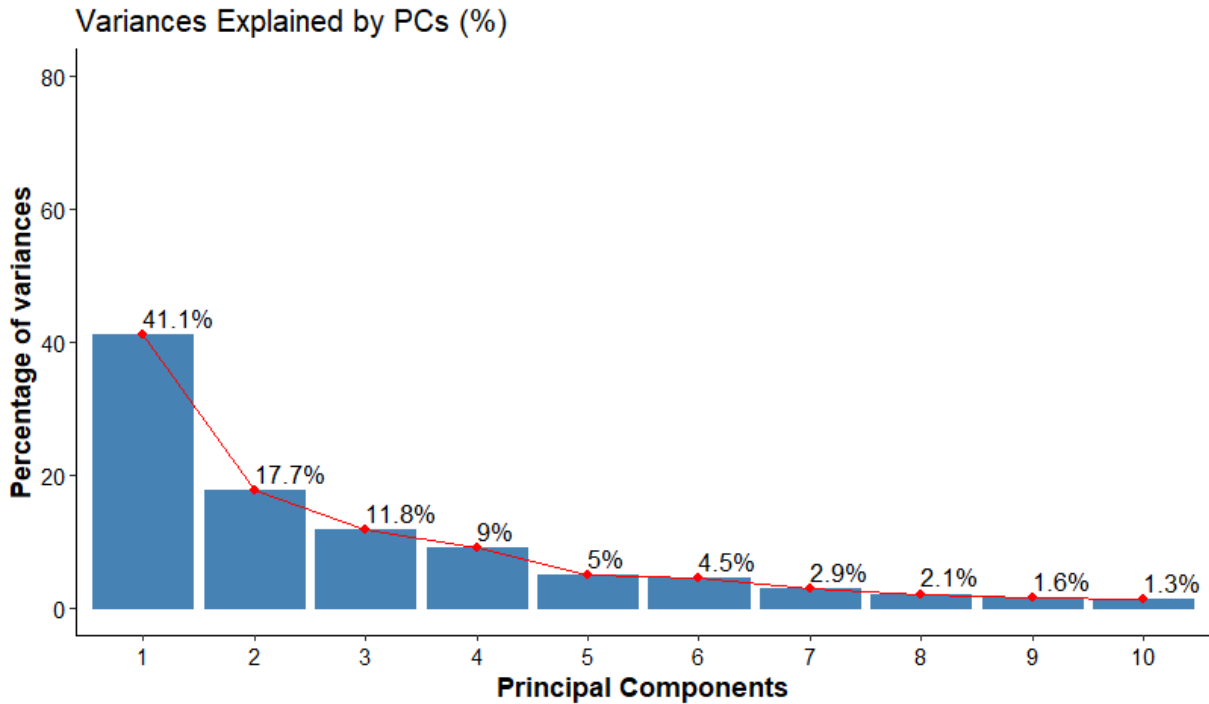


Fig 8. Graphic of PCs, explaining the variables of the two soils LVdf(Anionic acrudox)+LVAd (Typic hapludox)

Autovalues and Autovectors

	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Percentage of Autovalues and Autovectors										
Autovalue	8.21	3.54	2.36	1.80	1.01	0.91	0.59	0.43	0.32	0.27
Percentage of variance	41.07	17.72	11.78	9.02	5.03	4.54	2.93	2.15	1.60	1.35
Percentage of accumulated variance	41.07	58.79	70.56	79.58	84.61	89.14	92.08	94.23	95.83	97.18
Autovectors										
Bd	-0.01	-0.09	0.11	-0.63	0.09	-0.31	0.32	0.17	0.22	-0.34
Mg	-0.05	0.09	-0.57	-0.13	0.07	-0.29	0.15	-0.09	0.09	-0.18
Al	0.11	-0.22	0.51	-0.20	-0.02	0.08	-0.02	0.06	0.11	-0.11
Si	0.30	0.06	0.23	-0.20	-0.05	0.05	-0.13	-0.03	-0.08	-0.02
P	0.14	-0.18	0.32	0.39	0.10	-0.28	0.28	-0.17	0.04	-0.02
K	0.21	0.17	0.16	-0.35	-0.08	-0.05	-0.27	-0.62	-0.13	0.18
Ca	0.24	0.02	0.03	0.31	0.09	-0.39	0.28	-0.42	0.03	-0.13

Fig 9. Summary of the explanation of the PCs, explaining the variables of the two soils LVdf(Anionic acrudox)+LVAd (Typic hapludox)

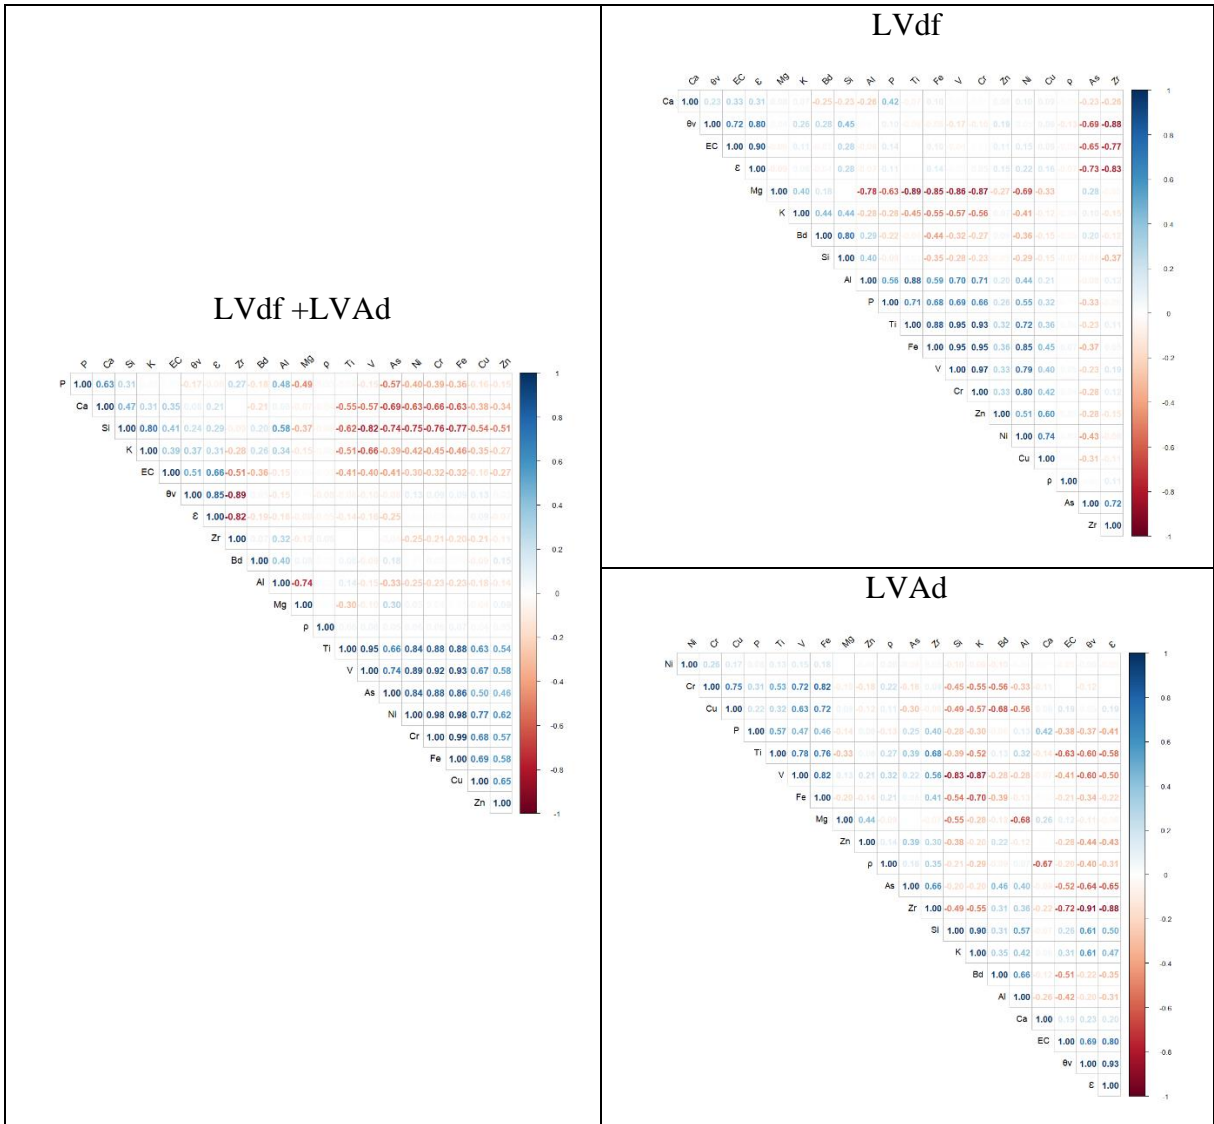


Fig 10. Correlations of the PCs of the variables, both with individual soils LVdf(Anionic acrudox), LVAd (Typic hapludox) and as a whole LVdf(Anionic acrudox)+LVAd (Typic hapludox).

CONSIDERAÇÕES FINAIS

Este estudo investigou os atributos físicos, químicos e mineralógicos do solo que podem afetar a porosidade (macroporos), seja por adensamento ou compactação. Foram desenvolvidos modelos de regressão para prever a densidade e o grau de compactação do solo, com o objetivo de reduzir o tempo, a mão de obra e os custos dos análises.

A partir da literatura e dos resultados experimentais, foi possível determinar que cada tipo de solo apresenta características específicas, indicando a necessidade de desenvolver modelos diferentes para cada subclasse de solo. Também se destacou que a maioria dos modelos de pedotransferência valoriza mais as propriedades do solo mais acessíveis (como o teor de carbono orgânico e a quantidade de argila) e frequentemente desconsidera as variáveis químicas devido ao alto custo e à falta de dados. Com o avanço da tecnologia, agora há maior acesso a esses tipos de análises, o que pode ajudar a expandir a base de dados, melhorar os modelos de previsão e encontrar novas soluções para prever as características de compactação dos solos. Se determinou que a fusão das características dos sensores proximais pode melhorar a precisão, o ajuste e o desempenho geral dos modelos, em comparação com o uso individual do sensor. Também se constatou que, embora um maior número de amostras nem sempre leve a um melhor desempenho, ajuste e precisão dos modelos, a estrutura e a textura do solo podem influenciar nos resultados.

Comparando os modelos com e sem o conteúdo de água (θ_v) ao longo da série temporal (de saturado a seco), não houve grande impacto na precisão e no desempenho dos modelos. Apenas alterou a ordem de importância de algumas variáveis, como o Fe em LVdf e o Si, Ti, Zn e ρ em LVAd. Considerando o potencial dos sensores individualmente, foi evidenciado que o espectrômetro de fluorescência de raios X gera modelos com maior desempenho e precisão, sem a necessidade de ser combinado com outros sensores.

Finalmente, não foi observado um padrão definido de distribuição das variáveis com base no grau de compactação. Contudo, pode-se afirmar que, nos solos compactados do subordem LVdf, as variáveis mais importantes foram Si, Fe, Ti, V, K e Al. Já no subordem LVAd, destacaram-se Cu, Al, Cr, Fe e Zn, mostrando relação com a mineralogia desses solos. Semelhante nos boxplots dos subordem onde os conteúdos de Si, Ca, Ti, V, Cr, Fe, Ni e As, fórum os mais representativos. Sendo que em solos compactados, apresento-se um incremento de Si no LVdf e um aumento de Al e diminuição de Cu na subordem LVAd. Também se observou uma grande variabilidade dos dados de CE com um amplo intervalo interquartil (IQR) em solos não compactados LVAd GC 70%.