

USO DA APRENDIZAGEM DE MÁQUINA A PARTIR DE IMAGENS PARA IDENTIFICAÇÃO DAS CLASSES TEXTURAIS DO SOLO

GUSTAVO DI CHIACCHIO FAULIN¹; MARCO ANTÔNIO LUDOVICO MARQUES²

¹Fatec Pompeia Shunji Nishimura – Mecanização em Agricultura de Precisão

²Instituto Politécnico de Setúbal - Portugal

gustavo.faulin@fatec.sp.gov.br

Use of machine learning from images for the identification of soil texture classes

Eixo Tecnológico: Recursos Naturais

Resumo

Esta pesquisa avaliou o uso de aprendizado de máquina como alternativa aos métodos laboratoriais convencionais de análise granulométrica do solo. Foram analisadas imagens digitais de 100 amostras de solo (20 de cada classe textural: Arenosa, Siltosa Média, Argilosa e Muito Argilosa) capturadas por microscópio digital (1.300x, 16 MP) e smartphone (13 MP). As imagens foram processadas no software Orange com o modelo SqueezeNet para extração de características. Diversos modelos de aprendizado de máquina foram avaliados, incluindo Regressão Logística, SVM, Random Forest, Redes Neurais, kNN e Árvore de Decisão, utilizando métricas como AUC, Acurácia, Precisão, Recall, F1-Score e MCC. A regressão logística obteve os melhores resultados, com acurácia de 73,0% (microscópio) e 78,1% (smartphone). Apesar da maior qualidade das imagens de microscópio, o smartphone favoreceu esse modelo específico. Houve maior dificuldade na distinção entre classes semelhantes, como Argilosa e Muito Argilosa. A combinação de aprendizado de máquina e dispositivos acessíveis mostra-se promissora para democratizar análises físicas de solo na agricultura de precisão. A ampliação do banco de dados e a padronização das imagens são estratégias fundamentais para aprimorar os resultados.

Palavras-chave: *Classes texturais, Física do solo, Textura do solo, Aprendizagem de máquina, Modelo supervisionado.*

Abstract

This study evaluated the use of machine learning as an alternative to conventional laboratory methods for soil particle size analysis. Digital images of 100 soil samples (20 from each textural class: Sandy, Silty, Medium, Clayey, and Very Clayey) were captured using a digital microscope (1,300x magnification, 16 MP) and a smartphone (13 MP). The images were processed using Orange software with the SqueezeNet model for feature extraction. Various machine learning models were evaluated, including Logistic Regression, SVM, Random Forest, Neural Networks, kNN, and Decision Tree, using metrics such as AUC, Accuracy, Precision, Recall, F1-Score, and MCC. Logistic regression achieved the best performance, with accuracies of 73.0% (microscope) and 78.1% (smartphone). Although microscope images offered higher quality, the smartphone yielded better results for this specific model. Challenges remained in distinguishing similar classes such as Clayey and Very Clayey. The integration of machine learning with accessible devices presents a promising approach to democratize physical soil analysis in precision agriculture. Expanding the dataset and standardizing image acquisition are key strategies for improving model performance.

Key-words: *Texture classes, Soil physics, Soil texture, Machine learning, Supervised model.*

1. Introdução

A textura do solo, determinada pela proporção de areia, silte e argila, é uma propriedade física essencial, com forte influência sobre a retenção e movimentação da água, disponibilidade de nutrientes, resistência mecânica e escolha de culturas agrícolas [1][2][3]. A caracterização textural convencional, baseada em métodos laboratoriais como a pipeta, é precisa, porém demanda tempo, mão de obra especializada e infraestrutura adequada [4][5].

Anais da VIII Mostra de Docentes em RJ

Nesse contexto, técnicas de aprendizado de máquina têm se destacado como alternativa promissora, oferecendo rapidez, reprodutibilidade e menor custo operacional. Modelos supervisionados como Regressão Logística, SVM e Redes Neurais vêm sendo empregados com sucesso na análise de imagens de solos, permitindo identificar padrões visuais associados à composição granulométrica, mineralógica e ao teor de umidade [6][4][7]. Além disso, avanços em visão computacional têm viabilizado o uso de dispositivos acessíveis, como smartphones, para capturar imagens com qualidade suficiente para análises automatizadas [7][8].

Estudos recentes demonstram que algoritmos como Redes Neurais Convolucionais (CNNs) são eficazes na classificação textural de solos em tempo real, mesmo sob condições operacionais variadas [7][9]. Modelos Random Forest também têm mostrado elevada acurácia na análise de textura, destacando sua robustez frente à variabilidade intrínseca dos dados [8].

Diante desse cenário, este trabalho propõe a aplicação de modelos de aprendizado de máquina para a classificação textural do solo, utilizando imagens obtidas por microscópio digital e câmera de smartphone. O objetivo é avaliar a acurácia dos algoritmos em identificar cinco classes texturais, buscando validar metodologias acessíveis e replicáveis para aplicação na agricultura de precisão.

2. Materiais e métodos


2.1. Materiais

Foram selecionadas 100 amostras de solo do banco de controle de qualidade do Laboratório Agrônomo da Fundação Shunji Nishimura de Tecnologia, distribuídas igualmente entre cinco classes texturais: Arenosa, Siltosa, Média, Argilosa e Muito Argilosa. A classificação foi realizada pelo método da pipeta [5], com base nas frações granulométricas de areia, silte e argila.

As amostras foram secas em estufa, homogeneizadas e acondicionadas em sacos plásticos identificados com a classe textural, número da amostra e sua composição granulométrica.

A aquisição das imagens foi realizada com dois dispositivos: Microscópio digital MOYSUWE MDM201 Pro, com ampliação de 1.300x e resolução de 16 MP (Fig. 1a) e; Smartphone Samsung A10, com câmera de 13 MP (Fig. 1b).

Fig. 1 - (a) Configuração do microscópio digital para captura de imagens; (b) Smartphone utilizado na aquisição.



Fonte: (Autores, 2024).

Cada amostra foi disposta em placas de Petri (60 × 15 mm) e nivelada para garantir uniformidade na superfície, minimizando distorções ópticas, especialmente nas imagens de microscópio.

2.2. Metodologia

Para as imagens obtidas com o microscópio digital, foram capturadas 10 imagens de cada placa de Petri em diferentes posições da superfície da amostra, totalizando 200 imagens por classe textural e 1.000 imagens no total. A ampliação da imagem foi ajustada de acordo com a altura focal da câmera do microscópio, com o objetivo de minimizar o desfoque causado pelos diferentes tamanhos das partículas, principalmente nas classes argilosa e muito argilosa.

A análise de classificação textural foi realizada no software Orange 3.36.2 [10], utilizando o modelo SqueezeNet para a extração dos vetores descritores das imagens. O conjunto de dados foi dividido aleatoriamente em 80% para treinamento e 20% para teste.

Os modelos de aprendizado de máquina avaliados foram: k-Nearest Neighbors (kNN), Regressão Logística, Support Vector Machine (SVM), Árvore de Decisão, Random Forest (RF), Rede Neural Artificial e um modelo Constante como referência.

Os parâmetros de desempenho analisados foram: Área sob a Curva ROC (AUC), Acurácia, Precisão, Recall (Revocação), F1-Score e Coeficiente de Correlação de Matthews (MCC). A AUC quantificou a capacidade discriminativa do modelo entre as classes texturais, enquanto a Acurácia representou a proporção total de acertos. A Precisão indicou a especificidade do modelo nas classificações positivas, e o Recall, a sensibilidade em identificar os positivos verdadeiros. O F1-Score integrou Precisão e Recall, e o MCC avaliou o equilíbrio entre as classes, sendo fundamental para conjuntos de dados balanceados.

Após a seleção do modelo com o melhor desempenho, foi gerada uma matriz de confusão para detalhar a precisão da classificação por classe textural.

3. Resultados e Discussão

A comparação entre os modelos supervisionados utilizados na classificação textural de imagens de solo obtidas com o microscópio digital (Tab. 1) e com o smartphone (Tab. 2) permite avaliar diferenças no desempenho dos algoritmos conforme a fonte de aquisição das imagens.

Tab. 1 - Parâmetros dos modelos supervisionados de aprendizado de máquina utilizados na classificação textural de imagens de solo obtidas com o microscópio digital.

Modelo	AUC ¹	Acurácia	F1-Score	Precisão	Recall ²	MCC ³
Regressão Logística	0,926	0,730	0,727	0,725	0,730	0,626
Rede Neural Artificial	0,920	0,718	0,711	0,712	0,718	0,606
SVM	0,912	0,710	0,709	0,715	0,710	0,597
kNN	0,900	0,707	0,700	0,702	0,707	0,592
Random Forest (RF)	0,881	0,666	0,653	0,657	0,666	0,530
Árvore de Decisão	0,716	0,606	0,603	0,601	0,606	0,454
Constante	0,465	0,398	0,226	0,158	0,398	0,000

Anais da VIII Mostra de Docentes em RJ

¹ AUC: Área sob a Curva ROC (acrônimo do inglês, Característica de Operação do Receptor);

² Revocação ou Sensibilidade; ³ MCC: Coeficiente de Correlação de Matthews.

Fonte: (Autores, 2025).

Tab. 2 - Parâmetros dos modelos supervisionados de aprendizado de máquina utilizados na classificação textural de imagens de solo obtidas com o smartphone.

Modelo	AUC ¹	Acurácia	F1-Score	Precisão	Recall ²	MCC ³
Regressão Logística	0,884	0,781	0,781	0,782	0,781	0,684
SVM	0,916	0,706	0,671	0,815	0,706	0,590
Random Forest (RF)	0,819	0,621	0,590	0,602	0,621	0,428
Rede Neural Artificial	0,820	0,615	0,588	0,646	0,615	0,417
kNN	0,843	0,611	0,594	0,631	0,611	0,426
Árvore de Decisão	0,732	0,601	0,600	0,603	0,601	0,425
Constante	0,360	0,421	0,250	0,177	0,421	0,000

¹ AUC: Área sob a Curva ROC (acrônimo do inglês, Característica de Operação do Receptor);

² Revocação ou Sensibilidade; ³ MCC: Coeficiente de Correlação de Matthews.

Fonte: (Autores, 2025).

De maneira geral, os modelos treinados com imagens do microscópio digital apresentaram desempenho superior em relação aos treinados com imagens do smartphone, evidenciado pelos valores mais altos de Acurácia, F1-Score e MCC. O melhor modelo em ambos foi a Regressão Logística, destacando-se por sua maior estabilidade nos diferentes conjuntos de dados. No entanto, na Tab. 1 (microscópio digital), esse modelo obteve Acurácia de 73,0%, F1-Score de 72,7% e MCC de 62,6%, enquanto na Tab. 2 (smartphone), esses valores foram 78,1%, 78,1% e 68,4%, respectivamente. Isso sugere que, para esse modelo específico, as imagens do smartphone resultaram em um desempenho ligeiramente superior, possivelmente devido a uma melhor adaptação às variações nos dados coletados provavelmente pela menor quantidade de amostras em cada classe.

Outro aspecto relevante é a diferença nos valores da AUC (Área sob a Curva ROC). Na Tab. 1, a Regressão Logística atingiu 0,926, enquanto na Tab. 2, esse valor foi menor, 0,884, indicando que a capacidade discriminativa do modelo foi um pouco reduzida quando treinado com imagens do smartphone. Em contrapartida, o modelo SVM, que na Tab. 1 apresentou AUC de 0,912, obteve um valor mais alto na Tab. 2, 0,916, sugerindo uma melhor identificação das classes ao utilizar imagens do smartphone.

Os modelos Random Forest, Redes Neurais, kNN e Árvores de Decisão apresentaram desempenhos inferiores em ambas as tabelas, mas com uma tendência de melhores resultados quando treinados com imagens do microscópio digital. Por exemplo, o Random Forest obteve uma Acurácia de 66,6% na Tab. 1 e apenas 62,1% na Tab. 2, e o MCC foi de 53,0% contra 42,8%, reforçando a ideia de que a qualidade e resolução das imagens do microscópio podem fornecer mais informações relevantes para a classificação.

Outro ponto de destaque é o desempenho do modelo Constante, utilizado como referência. Na Tab. 1, esse modelo apresentou AUC de 0,465 e acurácia de 39,8%, enquanto na Tab. 2, esses valores foram ainda menores, 0,360 e 42,1%, respectivamente. Essa diferença demonstra

Anais da VIII Mostra de Docentes em RJI

que os modelos supervisionados foram capazes de capturar padrões nos dados, mas o impacto da fonte das imagens ainda pode influenciar no desempenho geral.

Diante dessas análises, a Regressão Logística continua sendo o modelo mais robusto em ambas as condições, mas as imagens do smartphone demonstraram ser ligeiramente mais vantajosas para esse modelo específico. No entanto, considerando o desempenho geral dos demais modelos, as imagens do microscópio digital tendem a fornecer informações mais detalhadas para algoritmos como Random Forest, Redes Neurais e kNN, resultando em melhores métricas de avaliação. A escolha entre as fontes de imagem deve, portanto, considerar não apenas o modelo de aprendizado de máquina mais adequado, mas também a disponibilidade, custo e praticidade na aquisição das imagens no contexto de aplicação.

As Matrizes de Confusão para o modelo de Regressão Logística mostram informações importantes sobre o desempenho do modelo na classificação das imagens de solo, tanto para o microscópio digital (Tab. 3) quanto para o smartphone (Tab. 4).

Tab. 3 - Matriz de confusão para o modelo Regressão Logística na classificação de imagens de solo obtidas com um microscópio digital.

		Classe Textural - Predita				
		Arenosa	Siltosa	Média	Argilosa	Muito Argilosa
Classe Textural Atual	Arenosa	77,9%	0,0%	23,1%	0,9%	0,7%
	Siltosa	0,0%	83,5%	0,8%	0,1%	1,8%
	Média	19,1%	2,1%	56,0%	7,4%	7,7%
	Argilosa	2,7%	6,3%	15,6%	79,6%	26,0%
	Muito Argilosa	0,2%	8,1%	4,5%	12,1%	63,9%

Fonte: (Autores, 2025).

Tab. 4 - Matriz de confusão para o modelo Regressão Logística na classificação de imagens de solo obtidas com um smartphone.

		Classe Textural - Predita				
		Arenosa	Siltosa	Média	Argilosa	Muito Argilosa
Classe Textural Atual	Arenosa	82,6%	1,8%	0,0%	11,0%	1,6%
	Siltosa	0,0%	92,9%	6,9%	0,0%	1,6%
	Média	2,6%	5,4%	73,3%	8,0%	9,5%
	Argilosa	14,8%	0,0%	19,8%	76,8%	27,0%

Anais da VIII Mostra de Docentes em RJI

Muito Argilosa	0,0%	0,0%	0,0%	4,1%	60,3%
-----------------------	------	------	------	------	-------

Fonte: (Autores, 2025)

Ao observar a Tab. 3, que apresenta os resultados obtidos com o microscópio digital, é notável que a classe Siltosa foi corretamente classificada em 83,5% dos casos, indicando uma boa capacidade de discriminação dessa classe. Contudo, houve uma significativa confusão na classificação da classe Arenosa, com 23,1% das imagens Arenosas sendo incorretamente classificadas como Média, e 0,9% como Argilosa. Esse tipo de erro pode ser associado à similaridade visual entre essas classes, o que sugere a necessidade de um refinamento nos parâmetros do modelo para distinguir melhor essas categorias ou protocolos de coleta das imagens melhor adaptados para minimizar esse problema. De forma semelhante, as classes Argilosa e Muito Argilosa apresentaram taxas de erro consideráveis, com 26,0% das imagens Argilosas sendo incorretamente classificadas como Muito Argilosa, o que indica certa sobreposição nas características visuais dessas classes, exigindo ajustes na estratégia de classificação ou na qualidade das imagens.

Já a Tab. 4, referente ao modelo treinado com as imagens obtidas pelo smartphone, revela uma distribuição de acertos e erros distinta. A classe Siltosa apresentou a maior taxa de acerto, com 92,9%, o que demonstra que o modelo tem um bom desempenho na identificação dessa classe, similar ao que foi observado na Tab. 3. No entanto, a classe Arenosa também apresentou alta taxa de acerto (82,6%), mas com uma confusão considerável para Argilosa (11,0%) e uma pequena porcentagem para Muito Argilosa (1,6%). Isso pode sugerir que o modelo tem mais dificuldade em distinguir entre as classes de solos mais argilosos, possivelmente devido a características visuais que se sobrepõem nas imagens capturadas pelo smartphone. Observa-se que a classe Média teve uma taxa de acerto de 73,3%, com erros distribuídos entre Argilosa e Muito Argilosa, o que indica uma tendência de erro maior em solos com maior concentração de argila.

Em ambas as matrizes de confusão, um ponto crítico é a presença de erros de falsos negativos e falsos positivos, especialmente nas classes de solo com características mais similares entre si. Esses erros podem ser minimizados com o uso de técnicas de pré-processamento mais avançadas, como o aumento de contraste ou a segmentação mais precisa das imagens.

Diante dos resultados observados, foram definidas novas fases para o projeto, com a obtenção de um maior número de amostras para que o modelo se torne mais robusto e novas abordagens nos protocolos de coleta das imagens a fim de estabelecer padrões que favoreçam o modelo na classificação da textura do solo.

4. Considerações finais

A aplicação de algoritmos de aprendizado de máquina demonstrou-se eficaz na classificação da textura do solo a partir de imagens digitais. A Regressão Logística destacou-se como o modelo mais robusto, com desempenho superior em ambas as fontes de imagem. Embora as imagens do microscópio digital tenham proporcionado maior detalhamento e beneficiado modelos como Random Forest e Redes Neurais, as imagens do smartphone apresentaram ligeira vantagem para a Regressão Logística, sugerindo melhor adaptação a variações nos dados.

Referências

[1] BERTONI, J.; LOMBARDI NETO, F. **Conservação do solo**. 10. ed. São Paulo: Editora Ícone, 2017.

Anais da VIII Mostra de Docentes em RJI

- [2] CENTENO, L. N. et al. Textura do solo: conceitos e aplicações em solos arenosos. **Revista Brasileira de Engenharia e Sustentabilidade**, [S. l.], v. 4, n. 1, p. 31–37, 2017. <https://doi.org/10.15210/RBES.V4I1.11576>.
- [3] KLEIN, V. A. et al. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. **Ciência Rural**, [S. l.], v. 40, n. 7, p. 1550–1556, 2010. <https://doi.org/10.1590/S0103-84782010005000110>.
- [4] MA, R. et al. Toward Flexible Soil Texture Detection by Exploiting Deep Spectrum and Texture Coding. **Agronomy**, [S. l.], v. 14, n. 9, p. 2074, 2024. <https://doi.org/10.3390/agronomy14092074>.
- [5] DONAGEMMA, G. K. et al. Análise granulométrica. In: TEIXEIRA, P. C. et al. (org.). **Manual de métodos de análise de solo**. 3ª ed. Brasília, DF: Embrapa, 2017. p. 573.
- [6] KAPLAN, S. et al. Machine learning and computer vision technology to analyze and discriminate soil samples. **Scientific Reports**, [S. l.], v. 14, n. 1, p. 11, 2024. <https://doi.org/10.1038/s41598-024-69464-7>.
- [7] FOTABONG, T. F. et al. Soil Analysis Using Deep Learning for Precision Agriculture. In: 1ST INTERNATIONAL CONFERENCE ON PIONEERING DEVELOPMENTS IN COMPUTER SCIENCE AND DIGITAL TECHNOLOGIES, IC2SDT 2024 - PROCEEDINGS 2024, **Anais [...]**: Institute of Electrical and Electronics Engineers Inc., 2024. p. 303–307. <https://doi.org/10.1109/IC2SDT62152.2024.10696104>.
- [8] CHUAH, C. W. et al. An Automated Machine Learning Workflow to Classify Soil Texture for Crop Yield. In: 2024 7TH INTERNATIONAL CONFERENCE ON COMPUTER INFORMATION SCIENCE AND APPLICATION TECHNOLOGY, CISAT 2024 2024, **Anais [...]**: Institute of Electrical and Electronics Engineers Inc., 2024. p. 1133–1139. <https://doi.org/10.1109/CISAT62382.2024.10695281>.
- [9] ZHANG, Pin et al. CNN-Based Intelligent Method for Identifying GSD of Granular Soils. **International Journal of Geomechanics**, [S. l.], v. 21, n. 12, p. 04021229, 2021. [https://doi.org/10.1061/\(asce\)gm.1943-5622.0002214](https://doi.org/10.1061/(asce)gm.1943-5622.0002214).
- [10] DEMŠAR, J. et al. Orange: Data Mining Toolbox in Python. **Journal of Machine Learning Research**, [S. l.], v. 14, p. 2349–2353, 2013.