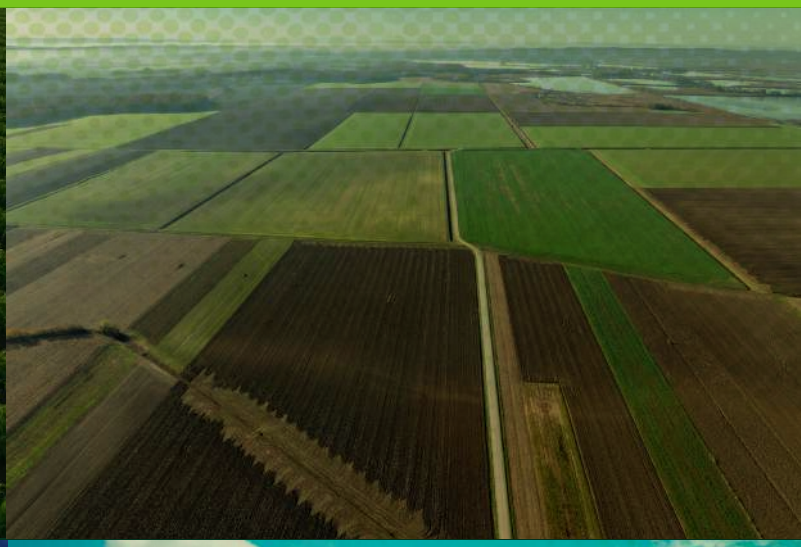
Ano 4 | nº 1 | Janeiro de 2026 | ISSN 2965-6389

Boletim Agronômico









AGRO EXTENSÃO

Inteligência artificial no apoio à tomada de decisão agronômica em solos

Luís Felipe Rossetto Gerlach[1], André Luis Vian[2], Teresa Enderle[3], Felipe Baudini da Silva[4]

[1]Doutorando PPG Fitotecnia UFRGS; [2]Prof. Dr. Faculdade de Agronomia UFRGS;

[3]Graduanda em Agronomia UFRGS; [4]Graduando em Agronomia UFRGS

Introdução

O manejo do solo permanece como um dos principais determinantes da produtividade e da estabilidade de rendimento em sistemas agrícolas, uma vez que atributos químicos, físicos e biológicos controlam a disponibilidade de nutrientes e água, a exploração radicular e a resiliência da lavoura frente a estresses ambientais (RABOT et al., 2018). Tradicionalmente, o diagnóstico de fertilidade tem se apoiado em amostragens pontuais, análises laboratoriais convencionais e interpretação por classes, a partir de manuais regionais de recomendação. Embora esse paradigma tenha permitido grandes avanços na correção e adubação de solos, ele apresenta limitações importantes em cenários de elevada variabilidade espacial, pressões por redução de custos, necessidade de maior densidade amostral e demanda por decisões mais rápidas e rastreáveis.

Paralelamente, a agricultura digital ampliou o volume e a diversidade de dados disponíveis sobre o solo. Hoje, resultados laboratoriais de pH, fósforo, potássio, bases trocáveis, matéria orgânica, CTC e saturação por bases podem ser combinados com informações de sensores espectrais (VIS–NIR, MIR, fluorescência de raios X), dados topográficos, imagens de satélite e mapas de colheita. A integração desses dados, entretanto, exige métodos analíticos capazes de lidar com relações não lineares, redundâncias e diferentes escalas temporais e espaciais, condições típicas de sistemas agrícolas (WOLFERT et al., 2017). Nesse cenário, técnicas de Inteligência Artificial (IA), especialmente as baseadas em Aprendizado de Máquina (Machine Learning), têm se consolidado como ferramentas promissoras para apoiar a tomada de decisão em solos, ao identificar padrões complexos e gerar estimativas espacialmente contínuas de atributos e respostas agronômicas (LIAKOS et al., 2018).

Estudos recentes têm demonstrado que modelos de ML podem ser utilizados para predizer atributos de fertilidade a partir de dados de sensores e covariáveis ambientais, reduzindo o custo e o tempo de laboratório e permitindo maior densidade amostral (JEON et al., 2024; RIBEIRO et al., 2024). Outros trabalhos mostram o uso de IA na otimização do planejamento amostral e no mapeamento digital de fertilidade, integrando análises de solo com relevo, uso da terra e sensoriamento remoto (PUSCH et al., 2023). Há ainda aplicações em que modelos de ML são empregados para estimar doses economicamente ótimas de fertilizante, evidenciando, ao mesmo tempo, o potencial e os riscos de se utilizar tais modelos diretamente para recomendação (TANAKA et al., 2024). Em paralelo, sistemas em tempo real vêm integrando sensores de solo, ML e deep learning para fornecer diagnósticos e recomendações diretamente ao produtor, por meio de plataformas conectadas (GUNASEKARAN & SREEVARDHAN, 2025).

Este boletim técnico tem como objetivo apresentar, de forma aplicada, como a Inteligência Artificial vem sendo utilizada ao redor da análise de fertilidade do solo, desde a predição de atributos químicos a partir de sensores até a otimização da amostragem e o suporte à recomendação de fertilizantes. A ênfase recai não apenas sobre o potencial dos modelos, mas também sobre seus limites, destacando a necessidade de validação, cautela na extrapo-

lação e protagonismo do agrônomo na interpretação dos resultados.

IA na análise de fertilidade: do laboratório aos sensores rápidos

A aplicação de IA na análise de fertilidade do solo pode ser compreendida em duas formas complementares. A primeira utiliza os resultados laboratoriais convencionais (pH, P, K, Ca, Mg, matéria orgânica, CTC, saturação por bases) como variáveis-alvo em modelos de ML para mapeamento digital de fertilidade ou para inferir atributos em locais não amostrados. A segunda integra sensores rápidos, como espectroscopia no infravermelho ou fluorescência de raios X, com algoritmos de ML, de modo a predizer atributos de fertilidade a partir de sinais espectrais, reduzindo o custo e o tempo da rotina analítica.

Na primeira abordagem, os dados laboratoriais convencionais são utilizados como base de calibração para modelos que exploram as relações entre atributos químicos do solo e variáveis espaciais, como relevo, uso da terra, índices de vegetação e informações de manejo. A integração de atributos de fertilidade, como CTC, saturação por bases, potássio e fósforo, com covariáveis ambientais e de manejo, aliada ao uso de modelos de aprendizado de máquina, como o Random Forest, e a técnicas de geoestatística robusta, tem demonstrado potencial para aprimorar simultaneamente o mapeamento digital da fertilidade e a eficiência do planejamento amostral (PUSCH et al., 2023). Os resultados indicam que essa combinação permite representar de forma mais precisa a variabilidade espacial dos atributos químicos, otimizando o número e a localização das amostras e refletindo diretamente na qualidade dos mapas e no diagnóstico de fertilidade.

Já na segunda abordagem, sensores espectrais vêm ganhando destaque como fontes de dados de alta resolução para IA em solos. Jeon et al. (2024), na Coreia do Sul, utilizaram espectroscopia no infravermelho médio (MIR) combinada a diferentes modelos de machine learning para prever múltiplos atributos do solo, incluindo pH, potássio trocável, nitrogênio total e outros parâmetros relevantes à fertilidade. Além de demonstrar boa acurácia na predição desses atributos, o estudo avaliou a viabilidade de usar os valores previstos como base para recomendações de fertilizantes, evidenciando o potencial da IA para aproximar sensores rápidos da rotina de recomendação agronômica.

De forma semelhante, Ribeiro et al. (2024) avaliaram o uso de um espectrômetro de fluorescência de raios X por energia dispersiva (EDXRF) acoplado a quatro algoritmos de ML para predizer atributos de fertilidade, como pH, carbono orgânico, soma de bases trocáveis e CTC, em comparação com métodos laboratoriais convencionais. Os autores destacaram que, embora a calibração e a seleção criteriosa de algoritmos sejam essenciais para evitar sobreajuste, a combinação de EDXRF e IA representa uma alternativa promissora para agilizar a avaliação de fertilidade e permitir maior densidade amostral.

Em conjunto, esses estudos ilustram uma mudança importante: a Inteligência Artificial deixa de ser aplicada apenas na etapa de interpretação dos resultados de solo e passa a atuar também na própria geração dos dados de fertilidade, seja por meio da extrapolação de análises laboratoriais no espaço, seja pelo uso de sensores rápidos calibrados por ML. Na prática, isso abre espaço para estratégias de monitoramento mais frequentes e densas, desde que acompanhadas de protocolos rigorosos de calibração, validação e controle de qualidade.

IA na otimização da amostragem e no desenho de estratégias de manejo

Um dos gargalos clássicos da análise de

fertilidade em nível de talhão é a definição de quantas amostras coletar e onde coletá-las. A adoção de grades fixas ou de amostragem por talhões inteiros nem sempre captura adequadamente a variabilidade espacial dos atributos do solo e pode resultar em custos elevados sem ganho proporcional de informação. Nesse contexto, a Inteligência Artificial e os métodos de mapeamento digital têm sido utilizados não apenas para predizer atributos de fertilidade, mas também para orientar o planejamento amostral, priorizando locais com maior incerteza ou maior potencial de contribuição para a qualidade dos mapas.

Pusch et al. (2023), por exemplo, utilizaram covariáveis ambientais (relevo, vegetação, manejo) e preditores, incluindo Random Forest e krigagem robusta, para otimizar o planejamento amostral em áreas agrícolas, com foco em atributos de fertilidade. Os autores mostraram que o uso de covariáveis em conjunto com modelos de ML permite selecionar pontos de amostragem mais informativos, reduzindo o número total de amostras necessárias para atingir determinado nível de acurácia, sem perder a capacidade de representar a variabilidade espacial dos atributos químicos. Em escala mais metodológica, Wadoux et al. (2019) investigaram estratégias de otimização do desenho amostral para mapeamento digital com Random Forest, comparando diferentes esquemas de amostragem e demonstrando que a distribuição espacial dos pontos utilizados na calibração influencia diretamente a acurácia dos mapas produzidos por ML.

Além da otimização do número e da localização de amostras, abordagens baseadas em variáveis auxiliares, como a condutividade elétrica aparente do solo (ECa), mapas de colheita ou índices de vegetação, têm sido empregadas para definir zonas preliminares de amostragem mais homogêneas, sobre as quais se constrói posteriormente o diagnóstico de fertilidade e o manejo localizado (SIQUEIRA et al., 2014; BOTEGA et al., 2022). Nessa lógica, a IA pode atuar tanto na modelagem direta dos atributos de solo quanto na identificação de zonas e gradientes prioritários para amostragem, contribuindo para que as unidades de decisão sejam definidas com maior embasamento e menor custo amostral. Quando combinadas, essas estratégias permitem que a análise de fertilidade evolua de esquemas fixos e pouco sensíveis à variabilidade para planos amostrais adaptativos, mais alinhados à realidade espacial do solo e às demandas de manejo de precisão.

IA na recomendação de fertilizantes e no manejo localizado

O uso de IA em fertilidade do solo tem avançado também no apoio direto à recomendação de fertilizantes, buscando estimar doses economicamente ótimas e personalizar o manejo por área ou zona. Estudos como o de Akhilesh et al. (2025) propõem sistemas de recomendação baseados em machine learning que integram tipo de solo, níveis de nutrientes e condições ambientais para sugerir doses de N, P e K em uma interface voltada ao usuário final. Enquanto Gunasekaran & Sreevardhan, (2025) descrevem uma plataforma em tempo real que combina ML e deep learning para análise de fertilidade, previsão de cultura e geração de insights integrados. Em comum, esses trabalhos apontam que a IA pode atuar como uma camada adicional de síntese, útil para explorar cenários e identificar oportunidades de ajuste fino das doses, mas que deve ser utilizada como ferramenta de apoio à decisão, sempre ancorada em critérios agronômicos, econômicos e ambientais.

Desafios, limites e boas práticas para adoção da IA em fertilidade do solo

Apesar do potencial demonstrado, a adoção de IA em fertilidade do solo enfrenta desafios importantes. O primeiro é a depen-

dência de dados de boa qualidade: modelos de ML refletem o conjunto de dados usados na calibração; se as análises de solo forem inconsistentes, se o histórico de manejo estiver incompleto ou se os mapas de colheita apresentarem ruído não tratado, a saída do modelo será, inevitavelmente, pouco confiável. Além disso, muitos estudos são desenvolvidos em condições específicas de solo, clima e sistema produtivo, aplicar diretamente esses modelos em outras regiões implica alto risco de extrapolação fora do domínio, com recomendações que podem não ser agronomicamente válidas. Outro limite relevante é a própria natureza de boa parte dos modelos utilizados. Embora técnicas de interpretação venham avançando, ainda é comum que o usuário não consiga identificar com clareza quais variáveis estão conduzindo a recomendação ou o diagnóstico. Isso aumenta o risco de naturalizar correlações espúrias ou de reforçar padrões indesejáveis presentes nos dados históricos (por exemplo, subadubação crônica em determinadas áreas). Há também desafios de implementação prática: integração entre bancos de dados, compatibilidade com sistemas de gestão, capacitação de equipes e tempo disponível para interpretar e validar as saídas dos modelos.

Diante desses pontos, algumas boas práticas podem orientar a adoção responsável da IA em fertilidade do solo. Em primeiro lugar, tratar a IA como ferramenta de apoio à decisão, e não como substituta de manuais, boletins e experimentos agronômicos. Recomendações derivadas de modelos devem ser confrontadas com faixas de suficiência, níveis críticos e metas de longo prazo para o sistema. Em segundo lugar, avançar de forma gradual, priorizando inicialmente aplicações com menor risco (por exemplo, uso de IA para melhorar mapeamento e amostragem) e introduzindo recomendações automatizadas apenas após testes e validação. Por fim, é recomendável documentar o processo (quais dados foram usados, qual modelo, qual versão, qual critério de validação) e priorizar a interpretação dos resultados, garantindo que cada decisão de manejo seja tecnicamente justificável, rastreável e coerente com os objetivos de produtividade, sustentabilidade e conservação do solo.

Conclusão

A aplicação de Inteligência Artificial à fertilidade do solo tem ampliado de forma consistente o leque de ferramentas disponíveis. Em torno da análise de fertilidade, a IA aparece em diferentes etapas do processo, desde a predição de atributos químicos, até a otimização da amostragem e o apoio à recomendação de fertilizantes. Em comum, essas aplicações buscam aumentar a densidade e a qualidade da informação disponível por unidade de área, reduzir custos de diagnóstico e tornar a tomada de decisão mais bem fundamentada e rastreável.

Ao mesmo tempo, os estudos recentes mostram que o ganho real não está em substituir completamente rotinas consolidadas, mas em qualificar o que já é feito, melhorar o desenho amostral, refinar o entendimento da variabilidade espacial, priorizar áreas de intervenção, testar cenários de manejo e identificar incoerências entre o que se aplica e o que o solo e a cultura de fato respondem. Quando bem calibrados e validados, os modelos de IA podem apoiar a identificação de padrões que seriam difíceis de capturar apenas com análises tradicionais, especialmente em sistemas com grande volume de dados históricos.

Por outro lado, a adoção responsável dessas ferramentas exige reconhecer seus limites, dependência de bases de dados consistentes, risco de extrapolação, necessidade de validação local e importância de manter a decisão ancorada em critérios agronômicos, econômicos e ambientais.

Em síntese, a IA deve ser vista como

uma camada adicional de inteligência sobre a análise de fertilidade do solo e não como substituta. Integrada de forma crítica, gradual e validada em campo, ela tem potencial para transformar a variabilidade do solo em oportunidade de manejo, contribuindo para maior eficiência no uso de insumos, sustentabilidade dos sistemas agrícolas e estabilidade de rendimento ao longo do tempo.

Referências

AKHILESH, S.; ABBURI, B. T.; SOMYA, P.; KRISHNA, R. M. S.; SRIHARI, T. Fertilizer recommendation for agriculture using machine learning. **International Journal of Multidisciplinary Research and Growth Evaluation**, v. 6, n. 2, p. 756–760, 2025. Disponível em: https://doi.org/10.54660/.IJMRGE.2025.6.2.756-760

BOTTEGA, E. L.; SAFANELLI, J. L.; ZERAATPISHEH, M.; AMADO, T. J. C.; QUEIROZ, D. M. de; OLIVEIRA, Z. B. de. Site-specific management zones delineation based on apparent soil electrical conductivity in two contrasting fields of southern Brazil. **Agronomy**, v. 12, n. 6, 1390, 2022. Disponível em: https://doi.org/10.3390/agronomy12061390

GUNASEKARAN, K.; A., K.; SREEVARDHAN, P. Real-time soil fertility analysis, crop prediction, and insights using machine learning and deep learning algorithms. **Frontiers in Soil Science**, v. 5, 1652058, 2025. Disponível em: https://www. 10.3389/fsoil.2025.1652058

JEON, S. H.; JANG, H. J.; NG, W.; MINASNY, B.; KIM, S. H.; SHIM, J. H.; ROH, A.; KWON, S. I.; YUN, J.. Predicting soil properties for fertiliser recommendation in South Korea using MIR spectroscopy. **Geoderma Regional**, v. 39, e00901, 2024. Disponível em: https://doi.org/10.1016/j.geodrs.2024.e00901

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: A review. **Sensors**, v. 18, n. 8, p. 2674, 2018. Disponível em https://doi.org/10.3390/s18082674

PUSCH, M.; SAMUEL-ROSA, A.; MAGALHÃES, P. S. G.; AMARAL, L. R. Covariates in sample planning optimization for digital soil fertility mapping in agricultural areas. **Geoderma**, v. 429, 116252, 2023. Disponível em: https://doi.org/10.1016/j.geoderma.2022.116252

RABOT, E.; WIESMEIER, M.; SCHLÜTER, S.; VOGEL, H.-J. Soil structure as an indicator of soil functions: A review. **Geoderma**, v. 314, p. 122–137, 2018. Disponível em: https://doi.org/10.1016/j.geoderma.2017.11.009

RIBEIRO, J. V.; SANTOS, F. R. dos; ALVES, J. V. de O.; FOSSALUZA, M. S.; NOGUEIRA, I. M.; OLIVEIRA, J. F. de; BARBOSA, G. M. C.; MÜLLER, M. M. L.; BORECKI, R. A.; POTT, C. A.; MELQUIADES, F. L. EDXRF and Machine Learning for Predicting Soil Fertility Attributes. **Semina: Ciências Exatas e Tecnológicas**, v. 45, e51475, 2024. Disponível em: https://doi.org/10.5433/1679-0375.2024.v45.51475

SIQUEIRA, G. M.; DAFONTE, J. D.; LEMA, J. B.; ARMESTO, M. V.; SILVA, Ê. F. F. e. Using soil apparent electrical conductivity to optimize sampling of soil penetration resistance and to improve the estimation of spatial patterns of soil compaction. **The Scientific World Journal**, v. 2014, 269480, 2014. Disponível em: https://onlinelibrary.wiley.com/doi/10.1155/2014/269480

TANAKA, T. S. T.; HEUVELINK, G. B. M.; MIENO, T.; BULLOCK, D. S. Can machine learning models provide accurate fertilizer recommendations? **Precision Agriculture**, v. 25, p. 1839–1865, 2024. Disponível em: https://doi.org/10.1007/s11119-024-10136-x

WADOUX, A. M. J.-C.; BRUS, D. J.; HEUVELINK, G. B. M. Sampling design optimization for soil mapping with random forest. **Geoderma**, v. 355, p. 113913, 2019. Disponível em: https://doi.org/10.1016/j.geoderma.2019.113913

WOLFERT, S.; GE, L.; VERDOUW, C.; BOGAARDT, M.-J. Big data in smart farming – A review. **Agricultural Systems**, v. 153, p. 69–80, 2017. Disponível em: https://doi.org/10.1016/j.agsy.2017.01.023