

ESTUDOS SOBRE MODELAGEM E MAPEAMENTO COM USO DE APRENDIZAGEM PROFUNDA NO CRESCIMENTO RADICULAR DE CULTIVARES

Ademir Xavier de Souza

Doutorando em Engenharia Elétrica e Computação (UFG)
Mestre em Ensino de Física (UFCAT)

Cacilda de Jesus Ribeiro

Doutora em Engenharia Elétrica (USP)
Professora Titular da Universidade Federal de Goiás

Wesley Pacheco Calixto

Doutor em Engenharia Elétrica (UFU)
Professor no Instituto Federal de Goiás/Câmpus Inhumas

RESUMO

Tecnologias avançadas na agricultura de precisão são aplicadas no estudo da arquitetura radicular otimizando o crescimento, produtividade e promovendo uma agricultura mais sustentável, eficiente e regenerativa do solo. Nesse sentido, o objetivo deste trabalho é apresentar uma revisão literária analisando o uso da inteligência artificial no contexto da agricultura de precisão sobre modelagem e mapeamento radicular de cultivares com auxílio de redes neurais. Essa abordagem se justifica à medida que estas ferramentas se tornam capazes de adaptar-se às mudanças nas condições de solo e planta, aprendendo com erros e aprimorando-se continuamente, tomando decisões sobre a aplicação de insumos e ajustes de manejo agrícola, construção e manutenção de base de dados, identificando desafios e possíveis melhorias no modelo com base na arquitetura radicular da planta. Os resultados apresentam uma economia no tempo de pesquisa, eliminação de ruídos e erros, detecção de imagens até então invisíveis e não interferência humana no desenho da arquitetura, calibração no monitoramento e ajuste de umidade. Dessa forma, conclui-se a importância de pesquisar e analisar diferentes tamanhos de amostras e explorar métodos de laboratórios e de campo menos onerosos e mais engenhosos na fenotipagem de raízes.

Palavras-chave: Aprendizagem profunda, Mapeamento, Modelagem, Rizotron, Sistema radicular.

1 INTRODUÇÃO

A sociedade contemporânea é formada por indivíduos integrados aos meios sociais de produção. O tradicionalismo do passado deve ser superado por ações e expressões que promovam e perpetuem o meio ambiente, atendendo as demandas sociais como alimentos, energia, água, solo, culturas, tecnologias entre outras, explorados com precisão [1]. A natureza de modo geral, funciona como mantenedora dos recursos necessários para sobrevivência e existência de qualquer forma de vida



no planeta. Esta relação simbiótica exclui de responsabilidade comportamental qualquer forma de vida, com exceção do homem, protagonista, transformador, racional, capaz de promover reflexões profundas sobre os meios de exploração dos sistemas naturais, ancorando-se na sustentabilidade, produtividade, eficiência e precisão em suas ações exploratórias. Estas ações se sustentam no pensamento filosófico, científico, e tecnológico oriundo de outras ciências, entre as quais se destaca a lógica que existe há dezenas de séculos [2].

A agricultura, por exemplo, é atividade necessária para a sobrevivência humana que, em última análise, deve ser menos invasiva e mais regenerativa com o ambiente natural. Na visão de [1] e [2], tecnologias de mapeamento e processamento de imagens usando inteligência artificial, como redes neurais, estão contribuindo e permitindo conhecer, qualitativamente, a dinâmica das raízes, suas variações na resistividade do solo seja em laboratório, seja em condições de campo. A rede neural permite a análise de situações complexas envolvendo múltiplas variáveis, sendo capaz de adaptar-se, a mudanças, aprender com erros, tomar decisões, aprimorar-se continuamente, enfrentando situações que necessitam de respostas e soluções, especialmente, sobre a arquitetura do sistema radicular.

2 OBJETIVO

O objetivo deste trabalho é apresentar uma revisão literária analisando o uso da inteligência artificial no contexto da agricultura de precisão sobre modelagem e mapeamento radicular de cultivares com auxílio de redes neurais, mostrando que tecnologias avançadas na agricultura de precisão são aplicadas no estudo da arquitetura radicular otimizando o crescimento, produtividade e promovendo uma agricultura mais sustentável, eficiente e regenerativa do solo.

3 METODOLOGIA

A pesquisa teve como alicerce uma revisão de literatura bibliográfica que emoldurou o quadro teórico e estruturou os conceitos para sua sustentação. A literatura utilizada fez uso de análise de obras já publicadas na forma de livros, artigos, teses e dissertações, todos relevantes para o tema apresentado, selecionando estudos primários e buscando base de dados.

4 DESENVOLVIMENTO

4.1 INTELIGÊNCIA ARTIFICIAL

Este estudo apresenta uma pesquisa bibliográfica sobre o uso de programas computacionais que requeiram máquinas para realizar tarefas cognitivas, as quais são executadas, normalmente, por humanos [3].

Um sistema de IA deve ser capaz de executar três tarefas [2]:

- a. armazenar conhecimento;



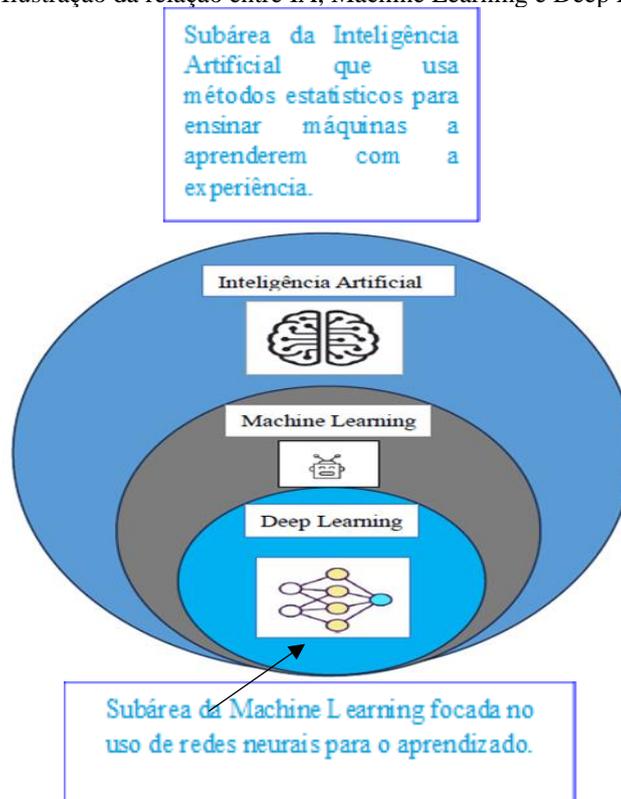


- b. aplicar conhecimento armazenado para resolver problemas; e;
- c. Adquirir novo conhecimento por meio da experiência.

A IA pode ser dividida em camadas, e dessa forma é introduzido os conceitos de Machine Learning (Aprendizagem de Máquina) e Deep Learning (Aprendizagem Profunda). Machine Learning, como o próprio nome já sugere, é o processo de aprendizado contínuo de máquina. O ensaio consiste em fornecer dados de entrada e com aprendizagem adquirida pelos mesmos elaborar saídas que satisfaçam a situação problema [4].

Um seguimento do Machine Learning é o Deep Learning que capacita a máquina a realizar tarefas mais complexas, como reconhecimento de fala, identificação de imagens e realizar previsões. O Deep Learning estabelece parâmetros básicos sobre esses dados e treina o algoritmo para aprender a usar várias camadas de processamento no reconhecimento de padrões [5]. Trata-se de imitar o aprendizado intuitivo humano, onde, com a experiência, têm-se a capacitação de executar uma série de atividades [6]. Nesse sentido, no Deep Learning (Fig.1) [7] as redes neurais são mais sofisticadas, de tamanho muito maior e com habilidade superior de extrair e representar informações.

Fig. 1. Ilustração da relação entre IA, Machine Learning e Deep Learning.



4.2 APLICAÇÕES NA AGRICULTURA

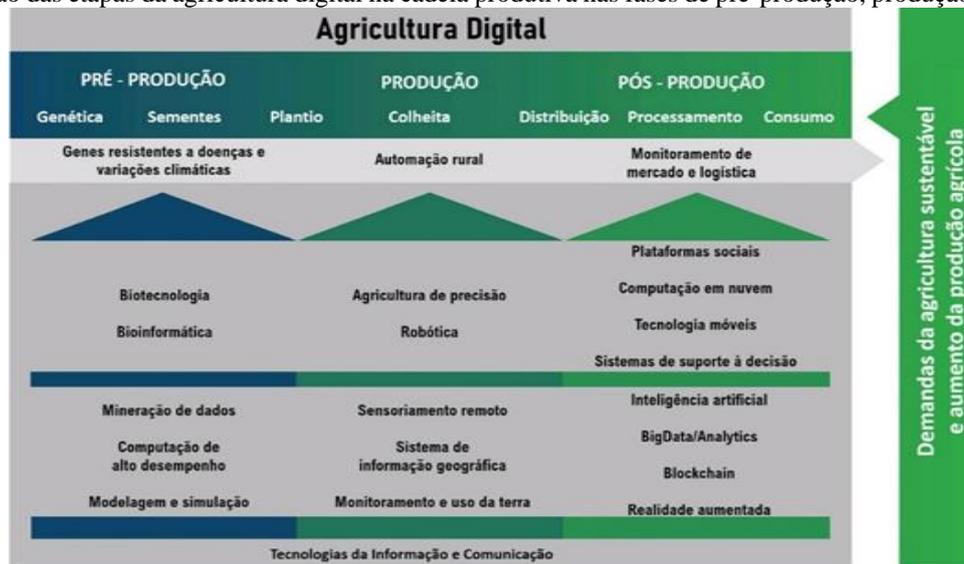
Existem ações voltadas à agricultura de precisão como gestão de coleta, processamento e análise de dados temporais, espaciais e individuais que associados a outras informações, permite-se obter uma



rede de apoio e gerenciamento na tomada de decisões estimulando melhoria na produtividade no uso de recursos, qualidade, rentabilidade e sustentabilidade [8].

Com o advento de certas tecnologias a agricultura foi se tornando cada vez mais digital (Fig.2) [9] à medida que o setor agrícola necessita cada vez mais da coleta massiva de dados para ajudar na tomada de decisões.

Fig. 2. Ilustração das etapas da agricultura digital na cadeia produtiva nas fases de pré-produção, produção e pós-produção.



A Embrapa propõe e participa neste novo Ecosistema (Fig.3) [9] de Inovação da Agricultura Digital, que é centrado na contribuição das novas tecnologias disruptivas para a agregação de valor à produção, o aumento da rentabilidade do agricultor e a segurança alimentar.

Fig. 3. Ilustração do Ecosistema de Inovação da Agricultura Digital.



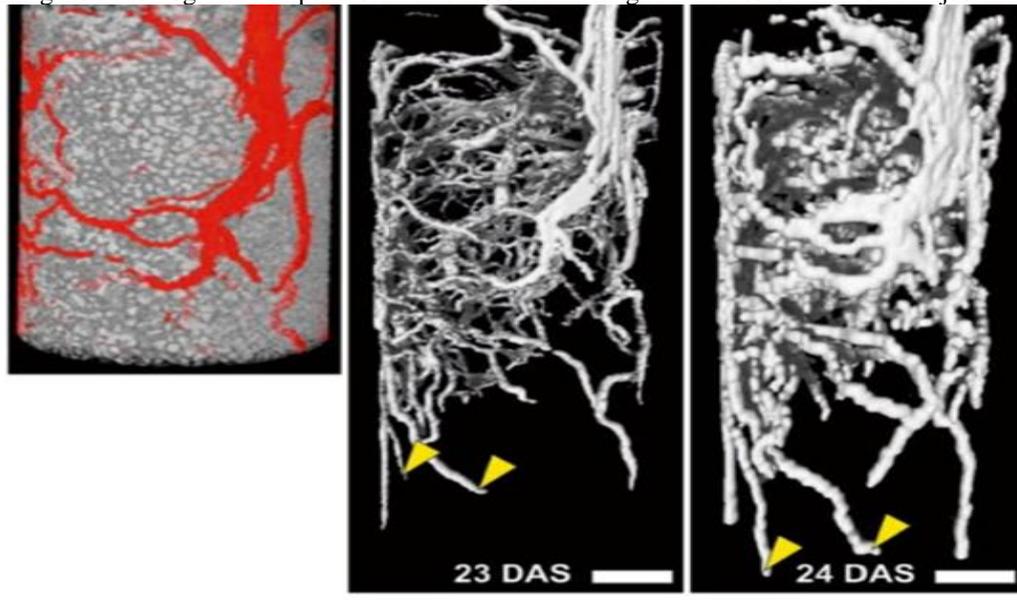
É necessário acreditar em uma Segunda Revolução Verde, uma iniciativa mundial com tripé em desenvolver técnicas de produção de alimentos, em solos com baixa fertilidade, de forma eficiente



e proficiente. Uma iniciativa dessa envergadura deve contar com apoio tecnológico de fronteira (programas computacionais, redes neurais artificiais, sensores) para mapeamento de solos e raízes, quanto seus requisitos químico-físicos e biológicos e o engajamento do meio acadêmico [10].

Na (fig.4) [11] tem-se imagens de tecnologias não destrutivas recentes, como a computação de raios X e tomografia que são extremamente caras e, portanto, estão além do alcance de programas comuns de melhoramento de culturas.

Fig. 4. Imagens de tomografia computadorizada e ressonância magnética de solo e raízes de feijão em rizotron.

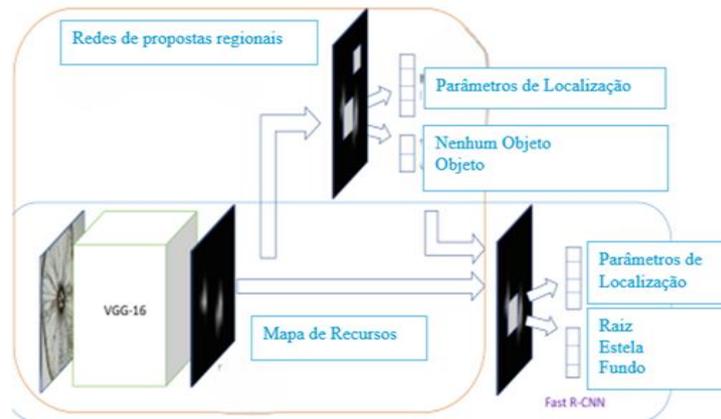


Para contornar esse problema valendo-se de avanços em aprendizagem profunda (DL) análise de imagens em uma abordagem sofisticada e integralmente autônoma, a rede Faster R-CNN (Rede Neural Convolutiva) para identificar e quantificar parâmetros anatômicos da raiz resolveu essa limitação [11].

Um modelo Faster R-CNN (Fig.5) [12] pré treinado, foi habilitado em imagens do sistema radicular do arroz. Ele conseguiu detectar imagens importantes de seção transversal das raízes (estela e metaxilema tardio). O modelo Faster R-CNN foi capaz de divulgar imagens até então invisíveis, isso eliminou a necessidade de interferência manual no desenho da arquitetura radicular (RSA), economizando tempo e eliminando ruídos e erros. Foi comparado os resultados da rede Faster R-CNN (um modelo de detecção de objetos) com os resultados obtidos usando a rede Mask R-CNN (um modelo de segmentação de instâncias) e mostrado que o modelo Faster R-CNN produz melhores resultados no geral, dado um pequeno conjunto de treinamento [12].



Fig. 5. Arquitetura de modelo R-CNN.



Enquanto a complexidade do ambiente se torna mais relevante para a produção em escala de campo e relevância fisiológica com métodos de campo, métodos controlados de laboratório são passíveis de fenotipagem e rendimento em larga escala; portanto, os pesquisadores continuam a explorar maneiras de preencher a lacuna entre métodos de laboratórios e de campo [13]. O principal impedimento são os altos custos de mão de obra e tempo no campo para fenotipagem de características de raiz. A capacidade de estudar tamanhos de amostras maiores fornecerá oportunidades interessantes para atender o papel do RSA (arquitetura do sistema radicular) e sua aplicação em pesquisas futuras [14].

4.3 ANÁLISE DE IMAGENS USANDO IA NO MAPEAMENTO DE RAIZ

Vários autores interessados em RSA comentaram que as qualidades amplamente invisíveis das raízes são um tópico de pesquisa fértil, mas frequentemente negligenciado [15].

Um ponto forte das técnicas de IA é a capacidade de detectar, classificar, quantificar e prever uma infinidade de características e padrões de dados de maneiras e quantidades que não são possíveis por humanos. Nos últimos anos, softwares como o RootPainter e o RhizoVision Explorer surgiram como os softwares preferidos para medições de raízes fazendo uso de técnicas não destrutivas para aquisições de imagens sem exigir que as raízes das plantas sejam removidas de seu ambiente de crescimento [16].

Existem várias vantagens em algumas técnicas de imagem não destrutivas, como a capacidade de conduzir análises de séries temporais (4D) e observar hábitos de crescimento sem perturbar (ou perturbar minimamente) a planta. Métodos 2D ou (2D + séries temporais), como rizotrons ou minirhizotrons, permitem que dados de séries temporais sejam coletados, o que permite que o crescimento incremental, hábitos de crescimento e outras atividades de crescimento subterrâneo, como nodulação e atividade micorrízica, sejam observados [17].

Embora não invasivas, as técnicas 3D diretas de campo, como medições de radar de penetração no solo de materiais radiculares finos e pelos radiculares, não são possíveis devido à falta de resolução



da tecnologia [13]. No entanto, o uso de outros sensores, como resistência eletromagnética, ressonância magnética (RM) [18], tomografia por emissão de pósitrons (PET) [19], tomografia computadorizada de raios X (TC de raios X) [20] e tomografia de nêutrons (NT) [21] foram bem-sucedidos em ambientes de estufa e laboratório. Porém, métodos não destrutivos falham em amostrar porções do sistema radicular de uma planta devido à natureza fina de algum material radicular ou pelos radiculares, conteúdo de água da raiz, presença de materiais de fundo para e ferromagnéticos que interferem nas varreduras, devido à opacidade do solo ou à área limitada da interação do solo e da raiz que são amostradas [22].

O radar de penetração do solo ou GPR é um método geofísico que emprega ondas eletromagnéticas para localizar estruturas e feições geológicas rasas, consiste na emissão e recepção de ondas eletromagnéticas refletidas nas interfaces do meio físico, produzindo como resultado uma imagem de alta resolução da subsuperfície [23]. Os principais fatores que controlam o sinal do equipamento são: a frequência e a velocidade da onda eletromagnética no meio, o coeficiente de reflexão (contraste de permissividade dielétrica entre os meios) e a atenuação do meio [24]. Dessa forma, a escolha da frequência central do GPR deve ser sempre precedida da identificação do solo, uma vez que a quantidade de argila, teor de sais ou água podem influenciar diretamente na atenuação do sinal do radar [25].

Antenas de altas frequências proporcionam melhores resultados em solos secos e eletricamente resistivos, de modo que a atenuação é proporcional à condutividade elétrica do meio, ou seja, quanto maior a condutividade maior a atenuação da onda eletromagnética [24].

Frequência entre 900 MHz e 1,5 MHz têm sido utilizadas para algumas investigações rasas e também em solos arenosos. Contudo, as antenas mais utilizadas para investigações de solo têm frequência central entre 100 e 500 MHz, pois conseguem atingir uma maior profundidade. Para solos orgânicos, responsáveis por uma elevada atenuação do sinal eletromagnético, onde grandes profundidades de investigação são necessárias à pesquisa, antenas de baixas frequências, entre 70 e 200 MHz, são comumente utilizadas. A seguir, a tabela I [25] mostra a variação de propriedades físicas de alguns solos em função de suas composições.



Tabela I - Intervalo da Constante Dielétrica, Condutividade Elétrica e Permeabilidade Magnética

Tipo de Solo	K	μ_r	σ_e (mS/m)
Solo arenoso	2,6	1	0,14
Solo arenoso	2,6	1	0,14
Saturado	2,4	1	6,9
Solo argiloso	15	1	0,27
Solo argiloso	15	1	0,27
Solo saturado	2,4	1	50
Raiz	3 - 5	1	<0,1

Na aquisição de dados foi utilizado o GPR modelo SIR-000 (fabricado pela empresa Geophysical Survey Systems, Inc.) acoplado a um par de antenas blindadas com frequência central de 900 MHz e uma roda odométrica (Fig.6) [23]. Os dados foram adquiridos através da técnica do afastamento comum, onde um par de antenas (uma transmissora e outra receptora) é deslocado ao mesmo tempo ao longo de cada perfil, permitindo uma visualização em tempo real dos refletores no subsolo. Os dados foram coletados ao longo de perfis de 4 m, equiespaçados em 5 cm, onde as três espécies ficaram no centro de uma área de 16 m², para cada um dos levantamentos.

Fig. 6. Disposição do Sistema GPR utilizado na aquisição de dados.



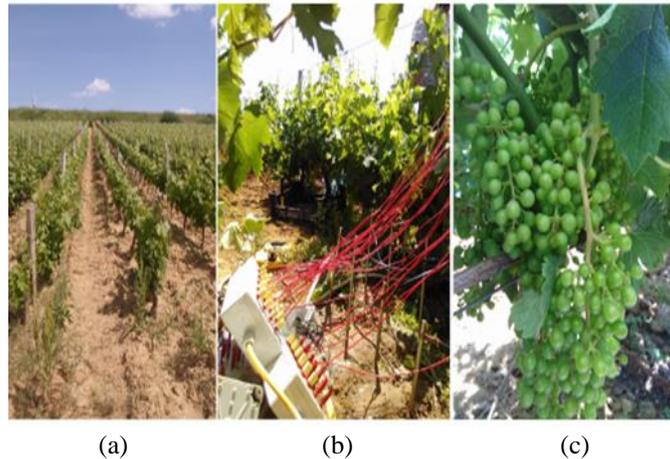
Após a etapa de aquisição, os dados foram processados no software ReflexW, versão 6.0 [26]. As etapas da rotina de processamento foram aplicadas de acordo com as características dos dados e dependem, fundamentalmente, do intérprete [27].

A utilização de métodos elétricos, como a tomografia de resistividade elétrica (TRE) e mise-à-la-masse (MALM) no monitoramento de raízes de cultivares, no caso, vinha em Bordéus/França (Fig.7). [28], se deu com o uso de corrente elétrica aplicada no solo, caracterizando-se por um comportamento não invasivo, permitindo conhecer imagens que de outra forma só poderiam ser apresentadas em locais geograficamente limitados. O MALM utiliza corrente elétrica contínua (CC),



aplicada no caule da cultura, obtendo imagens do sistema radicular. Desta forma, ERT e MALM, em conjunto, fornecem informações complementares sobre a estrutura e dinâmica das raízes. O modelo empregado permitiu conhecer, qualitativamente, variações na resistividade do solo, apresentando-se promissor em várias escalas, seja em laboratório, seja em condições de campo.

Fig. 7. Cultura em maio de 2017. Sendo: (a) local de campo (b) plantas investigadas (c) estado da uva durante o experimento.

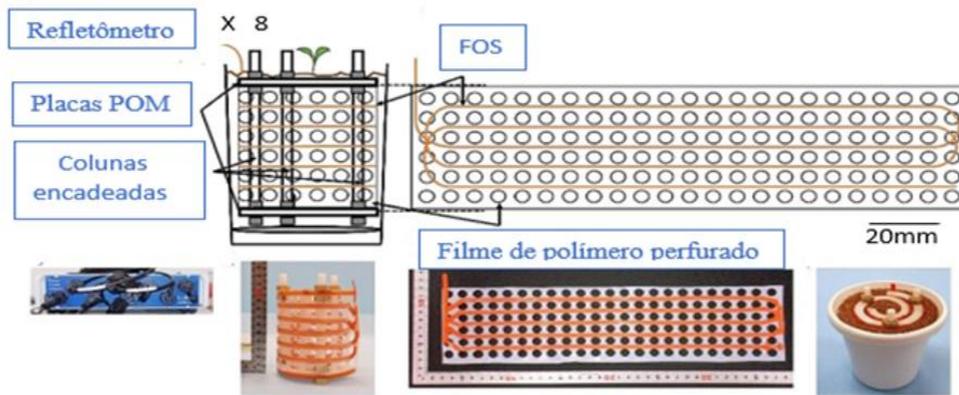


A abordagem por meio de MALM foi logisticamente a mesma que a de ERT e foi suportada pelo mesmo dispositivo, mas usou um esquema de polo-polo (com dois eletrodos remotos). Os eletrodos de perfuração e de superfície que compõem a configuração de medição foram usados como eletrodos potenciais, enquanto o eletrodo de corrente C1 foi plantado diretamente no caule, a 10 cm da superfície do solo, com uma profundidade de inserção de cerca de 2 cm, para injetar corrente diretamente na camada de câmbio. Os dois eletrodos remotos C2 (para atual) e P2 (para voltagem) foram colocados aproximadamente a uma distância de 30 m do gráfico, em direções opostas. Note que para MALM (diferentemente de ERT) um eletrodo de superfície de canto foi colocado perto da haste para refinar a informação no centro de cada retângulo.

Cada aquisição MALM foi acompanhada por uma aquisição MALM complementar, onde o eletrodo atual C1 era colocada diretamente no solo próximo ao caule em vez de no caule em si. Dessa forma, o efeito do sistema caule-raiz da planta na transmissão de corrente pode ser evidenciado diretamente comparando os padrões de voltagem resultantes das duas configurações MALM. A seguir, a (Fig. 8) [27] mostra condições atmosféricas variáveis no tempo usadas para simulação hidrológica.



Fig. 9. Esquema e fotos de um dispositivo FOS concluído.



Alguns pesquisadores [30] buscaram entender a cultura do sorgo quanto às suas características mensuráveis sob estresse hídrico, mapeando a estrutura radicular e seus padrões de absorção de água. O objetivo do estudo foi comparar o grau de absorção de água correlacionado com o desenvolvimento das raízes e a estrutura aérea da cultura do sorgo (*Sorghum bicolor* cv. Sucro 506) com as do milho (*Zea mays* cv. PR32F73). O sistema utilizou vinte Rizotrons de 1m³, nos quais foram inseridas sondas calibradas de umidade do solo, capazes de monitorar e ajustar o teor desta umidade em 25% e 12%, estresse hídrico. A cultura do sorgo manteve sua atividade fisiológica em contraste com o milho, ou seja, a eficiência no uso da água aumentou 20% na cultura do sorgo e reduziu 5% na cultura do milho. A densidade do comprimento da raiz e a capacidade de absorção de água foram melhoradas na cultura do sorgo. A adaptação positiva do sorgo em relação ao milho se deu pela sustentação da atividade fisiológica e pelo aumento da estrutura radicular, permitindo melhor absorção da água.

Sabe-se que, as raízes são estruturas-chave para o desenvolvimento das culturas de modo geral. Estudar a estrutura radicular sob vários aspectos é desafiador e dispendioso [31]. O estudo utilizou sistema de Rizotron compartimentado, integrando características convencionais na avaliação de padrões de raízes em escala de campo e laboratorial. O sistema segmentou o teor de umidade do solo através da compactação cilíndrica do mesmo por meio do filme hidrofóbico de petrolato/parafina, permitindo arranjo diferente na estrutura radicular que favoreceu a conservação de água pelas raízes rasas e profundas no Rizotron. O sistema permitiu realizar um estudo de fenotipagem radicular em porções diferentes e distintas do solo. De tal maneira que [32] discorrem sobre agricultura de precisão com o emprego de sensores que avaliam atributos do solo, cultura e tomadas de decisões no manejo agrícola. Isso ocorre com armazenamento, análise e transmissão de dados realizados por softwares automatizados. O resultado é um melhor gerenciamento espacial e temporal da cultura, obtendo máximo retorno econômico e reduzindo o impacto ambiental. Em sua tese de doutorado [33] propõe uma metodologia para obter a estratificação geolétrica do solo de múltiplas camadas sobrepostas horizontalmente. Essa estratificação é otimizada por uma curva de resistividade aparente experimental, obtida no solo, comparada com uma curva de resistividade teórica, desenvolvida por um algoritmo e



ilustrado na (fig. 10) [33]. O aspecto positivo dessa modelagem (Fig.11) [33] é que ela permite a estratificação do solo em várias camadas e em larga escala. O resultado da modelagem permitiu a aplicação do método na agricultura de precisão, pois o método proposto estima a condutividade elétrica das camadas do solo e suas respectivas profundidades.

Fig. 10. Curvas de resistividades aparentes. Sendo (a) crescente (b) decrescente.

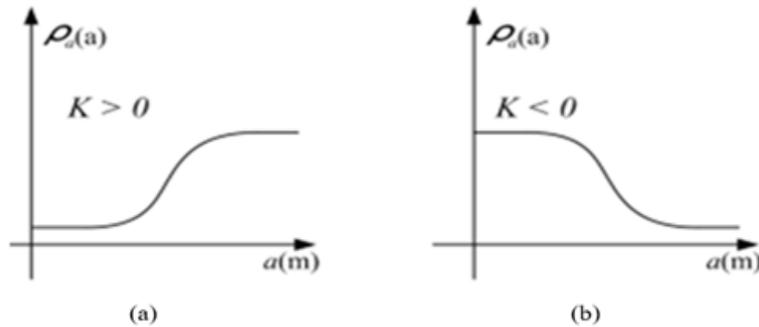
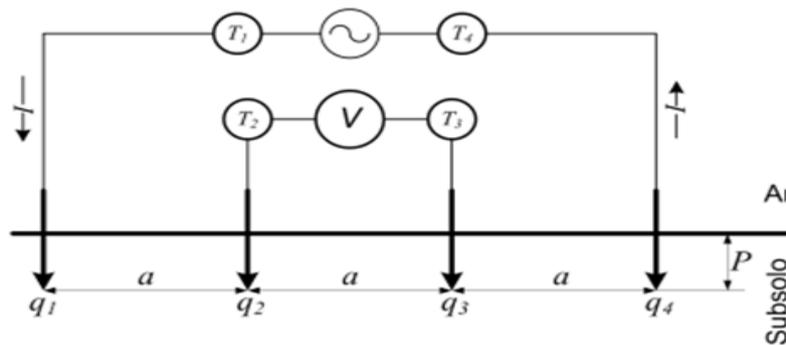


Fig. 11. Método de Wenner. Sendo (q) eletrodo (I) corrente elétrica (P) profundidade do eletrodo (a) espaçamento entre os eletrodos (V) ddp entre os eletrodos.



Em sua dissertação de mestrado [34] apresenta o estudo que relaciona a resistividade elétrica aparente do solo ρ_a , teor de umidade, de argila, compactação do solo, fazendo da ρ_a ferramenta de mapeamento da variabilidade espacial do solo. Os valores da ρ_a são obtidos por prospecção geoeletrica que detecta os efeitos da corrente elétrica no solo (Fig.12) [34]. A coleta de dados se faz usando o modelo de Wenner e a técnica de Caminhamento Elétrico (Fig.13) [34], permitindo concluir a relevância desta técnica para a AP, representando método não invasivo, ágil, econômico e de uso em larga escala. De modo geral, as diferentes abordagens, validadas por softwares computacionais, procuraram mapear o sistema radicular contemplando e parametrizando a estrutura aérea das culturas. No entanto, a estrutura que deve ser considerada localiza-se no subsolo, as raízes. A lacuna identificada reside na carência de estudos do sistema radicular na produção de alimentos, desoneração de custos e sustentabilidade dos sistemas naturais. Neste estudo, utiliza-se a inteligência artificial através da rede neural aplicada ao processamento de informações sobre a estrutura radicular das cultivares, visando entender a necessidade deste sistema quanto às propriedades físico-químicas para o seu melhor



desenvolvimento no espaço e no tempo, do ponto de vista de maior produtividade, mais economia e sustentabilidade. A rede neural permitirá a análise de situações complexas envolvendo múltiplas variáveis, sendo capaz de adaptar-se a mudanças, aprender com erros, tomar decisões, aprimorar-se continuamente, enfrentando situações que necessitam de respostas e soluções, especialmente, sobre a estrutura radicular.

Fig. 12. Ilustração do caminho da corrente elétrica no solo.

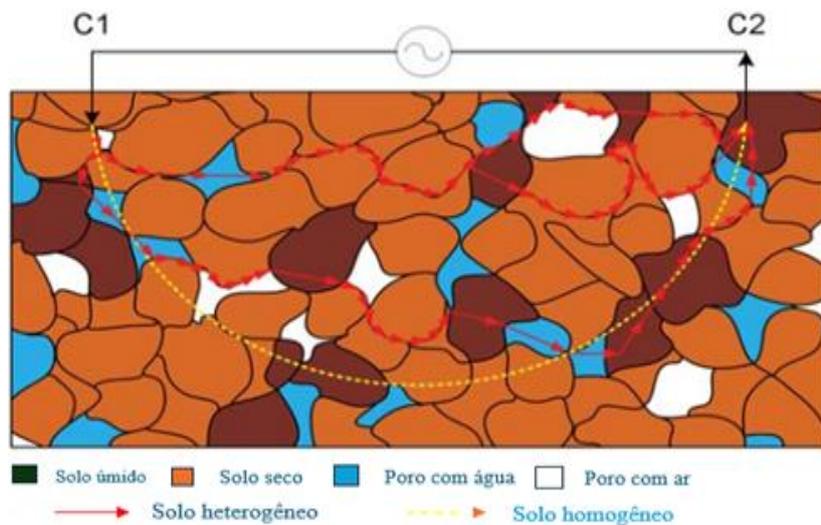
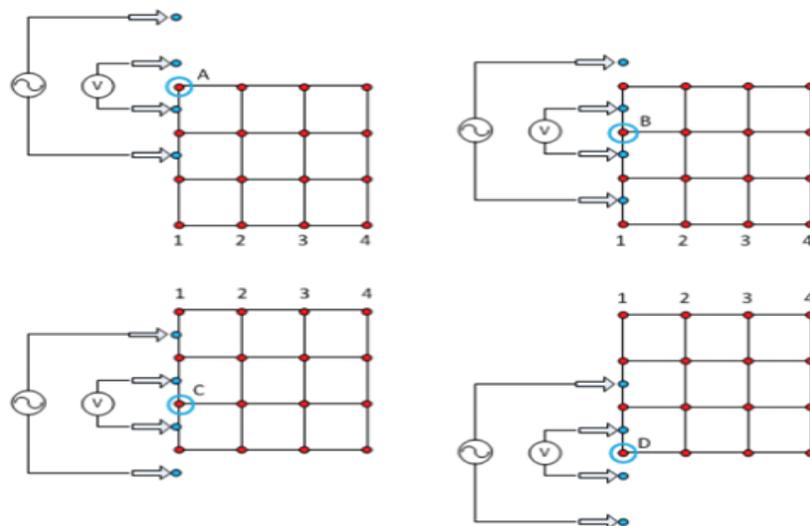


Fig. 13. Ilustração do método com Caminhamento Elétrico.

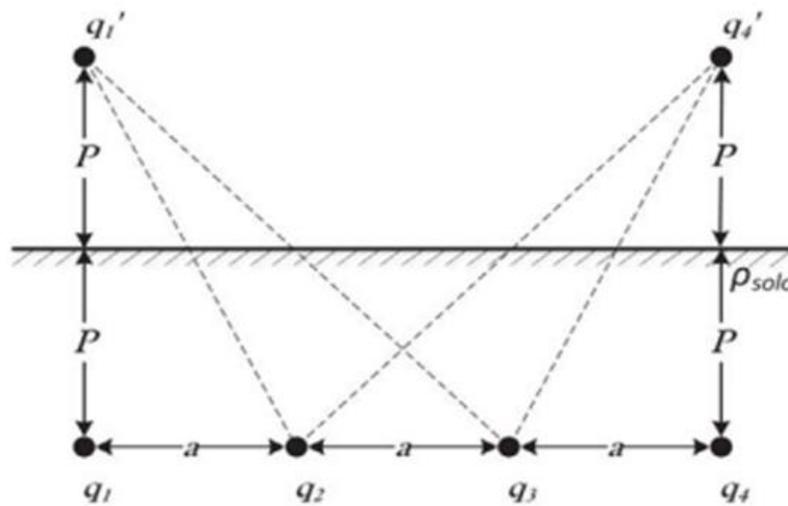


Este método foi proposto por F. Wenner, onde a corrente elétrica I é injetada no terminal T1 e coletada no terminal T4. Esta corrente, passando pelo solo entre os pontos q1 e q4, produz potencial nos pontos q2 e q3. Os potenciais nestes pontos podem ser encontrados em (1) [34]. Desta forma, a partir da (Fig.14) [34], que ilustra a imagem dos pontos q1 e q4, pode-se calcular os potenciais nos pontos q2 e q3, dados por (1) [34].



$$V_p = \frac{\rho l}{4\pi} \left(\frac{1}{r_1 q} \right) + \left(\frac{1}{r_1' q} \right) \quad (1)$$

Fig. 14. Ilustração do Arranjo de Wenner.



E finalmente, a resistividade elétrica do solo ρ_a [Ωm] é dada por (2) [34].

$$R_m = \frac{V_{23}}{I} = \frac{\rho}{4\pi} \left[\frac{1}{a} + \frac{2}{\sqrt{a^2 + (2p)^2}} - \frac{2}{\sqrt{(2a)^2 + (2p)^2}} \right] \quad (2)$$

5 CONSIDERAÇÕES FINAIS

Os estudos propostos permitiram realizar uma análise da fenotipagem radicular em porções diferentes e distintas do solo e comparar o grau da arquitetura radicular das plantas correlacionando-as com a absorção de água e demais nutrientes estimulados por suas funções bioquímicas. As pesquisas também conseguiram imagens mais detalhadas de partes finas das raízes, evitando-se a interferência humana para completar essas informações, manualmente, diminuindo a possibilidade de erros grosseiros. Essas abordagens solidificam o uso de programas computacionais como ferramentas que se tornam capazes de adaptar-se às mudanças nas condições de solo e planta, aprendendo com erros e aprimorando-se continuamente, tomando decisões sobre a aplicação de insumos e ajustes de manejo agrícola, construção e manutenção de base de dados, identificando desafios e possíveis melhorias no modelo com base na arquitetura radicular da planta. Os resultados apresentam uma economia no tempo de pesquisa, eliminação de ruídos e erros, detecção de imagens até então invisíveis e não interferência humana no desenho da arquitetura, calibração no monitoramento e ajuste de umidade e déficit hídrico. Dessa forma, conclui-se a importância de pesquisar e analisar diferentes tamanhos de amostras e explorar métodos de laboratórios e de campo menos onerosos e mais engenhosos na fenotipagem de raízes.



6 CONCLUSÕES

O governo federal, através da Embrapa, propõe uma inovação na agricultura digital com cerne no aumento da produção, rentabilidade e segurança alimentar. Rede Neural Convolutiva (R-CNN) tem sido utilizada para identificar parâmetros anatômicos da raiz de arroz, revelando imagens até então desconhecidas. O Faster R-CNN (modelo de rede para detecção da seção transversal da raiz) foi comparado com Mask R-CNN (modelo de rede para segmentação de instâncias) e o primeiro, no geral, produziu melhores resultados. O uso de radar de penetração no solo (GPR) produz imagens da subsuperfície e os melhores resultados tem-se mostrado para solos secos e eletricamente resistivos necessitando de um conhecimento prévio da composição do mesmo e suas propriedades físicas. O método elétrico, como a tomografia de resistividade elétrica (TRE) e mise-à-la-masse (MALM) uso de corrente elétrica aplicada no solo, em conjunto, apresentaram-se promissores em várias escalas, seja em laboratório, seja em condições de campo para reconhecimento na estrutura e dinâmica das raízes. O FOS (dispositivo acoplado a um sensor de fibra óptica) monitora em tempo real o desenvolvimento das raízes e tem-se mostrado superior a outras técnicas subterrâneas, tendo como resultado um melhor gerenciamento espacial e temporal da cultivar, obtendo máximo retorno econômico e reduzindo o impacto ambiental. A prospecção geoeletrica que detecta os efeitos da corrente elétrica no solo usando o modelo de Wenner e a técnica de Caminhamento Elétrico representam um método não invasivo, ágil, econômico e de uso em larga escala na AP. De modo geral, as diferentes abordagens, validadas por softwares computacionais, procuraram mapear o sistema radicular contemplando e parametrizando a estrutura localizada no subsolo em detrimento da parte aérea.



REFERÊNCIAS

1. GALVÃO, T. A. et al. Conceituação e estudo de normas. Brasília: CAT/SEDH/PR, 2009. p. 13-39.
 2. FRANCO, C. R. Inteligência Artificial. Londrina: Editora e Distribuidora Educacional, 2021.
 3. HAYKIN, S. Neural Networks: A Comprehensive Foundation. Prentice Hall, 2008.
 4. SHARMA, N. et al. Machine Learning and Deep Learning Applications-A Vision. Global Transitions Proceedings, v. 2, n. 1, p. 24-28, 2021.
 5. MANCO, L. et al. Basics of machine learning and deep learning in imaging for medical physicists. Physica Medica, v. 83, p. 194-205, 1 mar. 2021.
 6. DEBONA, D. G. et al. Sensory analysis and mid-infrared spectroscopy for discriminating roasted specialty coffees. Coffee Science, v. 16, 2021.
 7. BOT, J. L. et al. DART: software to analyse root system architecture and development from captured images. Plant Soil, p. 261-273. DOI: 10.1007/s11104-009-0005-2.
 8. SANTOS, J. B. et al. Caracterização e classificação de solos urbanos em Campina Grande do Sul, Estado do Paraná. Revista de Ciências Agrárias, Lisboa, v. 55, n. 2, p. 98-104, 2012.
 9. EMBRAPA. Agricultura Digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas. Brasília, 2020.
 10. LYNCH, J. P. Roots of the second green revolution. Australian Journal of Botany, Pennsylvania, v. 55, n. 14, p. 493-512, 2007.
 11. METZNER, R. et al. Direct comparison of MRI and X-ray CT technologies for 3D imaging of root systems in soil: potential and challenges for root trait quantification. Plant Methods, Jülich, 2015. DOI: <https://doi.org/10.1186/s13007-015-0060-z>.
 12. LYNCH, J. Root architecture and plant productivity. Plant Physiol., 1995, p. 7-13.
 13. ZHANG, Z. et al. Advances in root system architecture: Functionality, plasticity, and research methods. J Resour Ecol., 2022, p. 15-24.
 14. TOTZKE, C. et al. Capturing 3D water flow in rooted soil by ultra-fast neutron tomography. Sci Rep., 2017.
 15. UGA, Y. et al. Challenges to design-oriented breeding of root system architecture adapted to climate change. Breed Sci., 2021, p. 3-12.
 16. SEETHEPALLI, A. et al. RhizoVision Explorer: Open-source software for root image analysis and measurement standardization. AoB Plants, 2021.
 17. SEETHEPALLI, A. et al. An integrated hardware and software platform for root crown phenotyping. Plant Phenomics, 2020.
 18. ZHANG, Z. et al. Advances in root system architecture: Functionality, plasticity, and research methods. J Resour Ecol., 2022, p. 15-24.
-



19. METZNER, R. et al. Direct comparison of MRI and X-ray CT technologies for 3D imaging of root systems in soil: potential and challenges for root trait quantification. *Plant Methods*, 2015.
20. WASSON, A. P. et al. Noninvasive root and rhizosphere phenotyping. *Trends Plant Sci.*, 2020, p. 119-120.
21. FALK, R. et al. Computer vision and machine learning enabled soybean root phenotyping pipeline. *Plant Methods*, Ames, 2020. DOI: <https://doi.org/10.1186/s13007-019-0550-5>.
22. HUANG, Z. et al. Automatic segmentation of cotton roots in high-resolution minirhizotron images based on improved OCRNet. *Frontiers in Plant Science*, Agricultural Research Service (USDA), United States, 2023. DOI: <https://doi.org/10.3389/fpls.2023.1147034>.
23. ROCHA, G. et al. GPR 3D como método não invasivo para estudo do crescimento e biomassa de raízes de árvores de florestas tropicais. V Simpósio Brasileiro de Geofísica, 2012.
24. ANNAN, A. P. Ground penetration radar workshop notes. Sensors Software, Inc., Internal Report, 1992. 130 p.
25. DOOLITTLE, J. A. et al. Ground Penetrating Radar: Theory and applications. Chapter 6: Soils, peatlands, and biomonitoring. In: JOL, H. M. (Ed.). Elsevier Science, 2009.
26. SANDMEIER, K. J. REFLEXW, Version 6.0. Windows™ 9x/NT/2000/XP/7 – program for the processing of seismic, acoustic or electromagnetic reflection, refraction and transmission data. Manual. 516 p., 2011.
27. BORGES, W. R. et al. Aplicação da Geofísica Forense na Busca de Vestígios de Pessoas Desaparecidas na Guerrilha do Araguaia. In: IV Simpósio Brasileiro de Geofísica, Brasília-DF, 2010.
28. MARY, B. et al. Time-lapse monitoring of root water uptake using electrical resistivity tomography and mise-à-la-masse: a vineyard infiltration experiment. *Soil*, 2020, p. 95-114.
29. TEI, M. et al. Non-destructive real-time monitoring of underground root development with distributed fiber optic sensing. *Plant Methods*, 2024.
30. ZEGADA, L.; LIZARAZU, L. et al. Water uptake efficiency and above-and belowground biomass development of sweet sorghum and maize under different water regimes. *Plant and Soil*, p. 47-60, 2012.
31. SARTONI, R. et al. A new compartmentalised rhizotron system for root phenotyping. *Italian Journal of Agronomy*, p. 53-58, 2015.
32. BASSOI, L. H.; INAMASU, R. Y. Agricultura de precisão e agricultura digital. 2019.
33. CALIXTO, W. P. et al. Métodos matemático e computacional aplicados a prospecção geométrica com estratificação tridimensional. 2012.
34. SILVA, A. M. Metodologia para correlacionar a umidade, compactação e a condutividade elétrica aparente do solo. 2014.