

PROTOTIPO DE SENSOR DE ANÁLISE DE SOLO COM IA EMBUTIDA

SOIL ANALYSIS SENSOR PROTOTYPE WITH EMBEDDED AI

André Luiz Ricartes da Silva – andre.silva427@fatec.sp.gov.br
 Fatec - Jorge Caram Sabbag – Bebedouro – São Paulo – Brasil

Renan de Jesus Souza – renan.souza48@fatec.sp.gov.br
 Fatec - Jorge Caram Sabbag – Bebedouro – São Paulo – Brasil

prof. Me. Paulo Eduardo Cardoso Andrade – paulo.andrade19@fatec.sp.gov.br
 Fatec - Jorge Caram Sabbag – Bebedouro – São Paulo – Brasil

prof. Me. Renan Guilherme Nespolo – renan.nespolo01@fatec.sp.gov.br
 Fatec - Jorge Caram Sabbag – Bebedouro – São Paulo – Brasil

DOI: 10.31510/infa.v22i1.2040
 Data de submissão: 23/09/2024
 Data do aceite: 26/06/2025
 Data da publicação: 30/06/2025

RESUMO

A mais recente revolução na Agricultura, classificada como Agricultura 5.0, faz a união de vários aspectos tecnológicos, entre eles a Internet das Coisas (IoT), *Big Data* e Inteligência Artificial. No campo da agricultura de precisão, a leitura de nutrientes do solo ainda é realizada de forma laboratorial, expondo a amostra de solo a reagentes químicos para coletar os valores dos nutrientes; onde, assim, os sensores digitais que extraem a leitura de nutrientes do solo em tempo real. Embora muito mais rápidos que a análise laboratorial, apresentam também variações na leitura, que em relação a ela podem apresentar valores muito divergentes e, nesse contexto há um potencial de aplicações a serem explorados. Portanto, o presente estudo tem por objetivos explorar algoritmos de Inteligência Artificial (IA) para realizar tarefas de Regressão que embarcados em protótipos passam a realizar a leitura de fósforo e potássio no solo, o que melhorará a precisão das medições, indicando potencial para futuras aplicações e desenvolvimento

Palavras-chave: Agronegócio. Agricultura de Precisão. Machine Learning. IOT. Sensores.

ABSTRACT

The newest revolution in agriculture, classified as Agriculture 5.0, brings together various technological aspects, including the Internet of Things (IoT), Big Data and Artificial Intelligence. In the field of precision agriculture, the reading of soil nutrients is still carried out in a laboratory, exposing the soil sample to chemical reagents to collect the nutrient values. Digital sensors, on the other hand, extract nutrient readings from the soil in real time. Although they are much faster than laboratory analysis, there are variations in the readings, which

can be very different from laboratory analysis. In this context, there are potential applications to be explored. Therefore, the aim of this study is to explore Machine Learning algorithms to perform Regression tasks that are embedded in prototypes that read phosphorus and potassium in the soil, which has improved the accuracy of the measurements, indicating potential for future applications and developments.

Keywords: Agribusiness. Precision Agriculture. Machine Learning. IoT. Sensors.

1. INTRODUÇÃO

O agronegócio no Brasil tem desenvolvido taxas notáveis nos últimos anos, onde o setor supre o mercado nacional e contribui decisivamente para as exportações. Segundo o Instituto Brasileiro de Geografia e Estatísticas (IBGE), o Produto Interno Bruto (PIB) brasileiro fechou o ano de 2023 com R\$ 10,9 trilhões e fica 2,9% acima das previsões. Dessa maneira com crescimento de 15,1% comparado ao ano de 2022, as atividades agrícolas evidenciam a importância econômica e social no Brasil. BELANDI, (2024)

A agricultura de precisão possibilita produzir de forma inteligente e ferramentada com o uso de sensores de monitoramento em tempo real, proporcionando análises diárias onde desempenha papel fundamental nas “Fazendas Inteligentes”. A base de qualquer colheita saudável e produtiva é a qualidade do solo e tem como fator determinante na produção de culturas. A quantidade e a disponibilidade adequada de nutrientes, como Fósforo (P) e Potássio (K) são itens críticos e decisórios na produtividade das colheitas.

Os sensores fazem parte de uma tecnologia recente no campo, e entender a confiabilidade destes é fator primordial, especialmente nos parâmetros de solo. Para cada análise do laboratório além de demandar tempo de coleta, transporte e análise; o custo médio de uma análise laboratorial de solo fica em torno de R\$65,00 (PAULA, 2023). Deste modo, os objetivos do presente estudo buscam construir um protótipo que realize a análise de forma digital e instantânea, utilizando os materiais existentes no mercado e fundindo-os com IA para minimizar o erro entre a análise digital e a laboratorial dos macronutrientes como, Fósforo (P) e Potássio (K).

Dessa maneira, as principais contribuições do presente trabalho são:

- Desenvolver um protótipo que realize a leitura dos macronutrientes Fósforo (P) e Potássio (K);
- Embarcar o algoritmo de IA no protótipo do microcontrolador e;
- Minimizar o erro entre a leitura digital e a análise laboratorial utilizando o IA.

2. FUNDAMENTAÇÃO TEÓRICA

A domesticação de plantas e animais é um desenvolvimento recente na evolução humana (HARARI, 2013). Em 2015, surgiu a Agricultura Digital ou 4.0, que utiliza tecnologia e IoT para gerar dados e tomar decisões rápidas e assertivas. Com a adição de conectividade e Inteligência Artificial, iniciou-se a Agricultura 5.0, a quinta revolução no setor.

Entre as inovações estão o uso de sensores para coleta de dados em tempo real, e softwares de gestão, que proporcionam maior aproveitamento dos recursos, promovendo uma produção mais eficiente e sustentável (BARICHELLO, 2023).

2.1 Agricultura de precisão

Discutido, pelo menos, há 25 anos, de acordo com AMARAL et al. (2015), a expansão territorial da agricultura, promovida principalmente pelo advento da mecanização, permitiu que áreas cada vez maiores com diferentes solos e relevos fossem cultivadas e geridas sobre o preceito da desuniformidade dos terrenos. Segundo RAI (2014), a utilização de novas tecnologias no agronegócio, pode aumentar os rendimentos das safras em até 67% e proporcionar a redução dos preços em 50% até 2050.

Para VASCONCELOS (2023), a Agricultura de Precisão se diferencia do manejo convencional devido a eficácia do gerenciamento da variação espacial. A Associação Brasileira de Agricultura de Precisão e Digital (ASBRAAP) a define como “o conjunto amplo de técnicas e tecnologias que permitem o gerenciamento agrícola baseado na variabilidade espacial e temporal das unidades produtivas visando o aumento de retorno econômico e à redução do impacto ao ambiente” (ASBRAAP, 2016).

Os Sensores tornam possível o monitoramento de planta e solo, sua capacidade de coletar grande volume de dados, produzir informações de variabilidade espacial da área colabora para análise do perfil da lavoura. (COLAÇO e MOLIN, 2014). Segundo SOKOLOVA, (2021), o objetivo primordial na coleta de dados desses dispositivos permite a construção de conhecimento geoespacial, tornando possível identificar padrões que norteiam ações mais assertivas.

2.2 Análises de dados, regressão, avaliação e pré-processamento

Segundo A. SILVA & G. SILVA (2022), a disseminação da conectividade no campo e o aumento de dados no agronegócio exigem sistemas integrados. O uso de Big Data, modelos preditivos, ciência de dados e análise de dados estão otimizando processos e fornecendo novos

conhecimentos. No meio rural, ferramentas como IoT, Aprendizado de Máquina, IA, blockchain e outras tecnologias são aplicadas em equipamentos cada vez mais sofisticados.

O Aprendizado de Máquina, desempenha um papel crucial em ciência de dados, segundo ESCOVEDO e KOSHIYAMA (2020). Essa ferramenta, subconjunto da IA, permite o aprendizado e aperfeiçoamento de sistemas com base em dados. No Aprendizado, Supervisionada a Regressão permite realizar previsões de dados contínuos utilizando modelos e algoritmos. Dentre eles, o DWNN (*Distance Weighted Nearest Neighbors*), é bastante sucinto e pode ser embarcado em dispositivo com pouca memória de armazenamento. Esse algoritmo aplica a ponderação com base na distância entre o ponto de consulta e os pontos de treinamento, utilizando a função de valor discreto para ponderar o voto de cada vizinho de acordo com o inverso do quadrado de sua distância, como apresentando no algoritmo 1 (MITCHELL, 1997).

Algoritmo 1: DWNN

Entrada: X, y, φ, σ

Saída: \hat{y}

```

1    $w \leftarrow$  iniciar( )
2   for  $i$  in  $w$ :
3        $x \leftarrow X_i$ 
4        $w_i \leftarrow e^{-\frac{\|\varphi-x\|^2}{2\sigma^2}}$ 
5    $\hat{y} \leftarrow \frac{\sum_{i=1}^n (w_i \times y_i)}{\sum_{i=1}^n w_i}$ 

```

Fonte: (MITCHELL, 1997).

No qual \hat{y} é a representação da previsão gerada pelo algoritmo.

Para avaliação do método, a técnica de *Cross-Validation* foi selecionada. Para FRANK e WITTEN (2005) o *10-Fold-Cross-Validation* ou *k-Fold Cros-Validation* é a forma padrão de medir a taxa de erro de um esquema de aprendizagem em um conjunto de dados específicos, para fins de resultados confiáveis, utilizando validação cruzada.

3. MATERIAIS E MÉTODOS

A metodologia adotada neste estudo caracteriza-se por ser uma pesquisa descritiva com abordagem quantitativa, operacionalizada por meio da análise de dados coletados. Ao discutir as características da pesquisa qualitativa, CRESWEL (2007) chama a atenção para o fato de

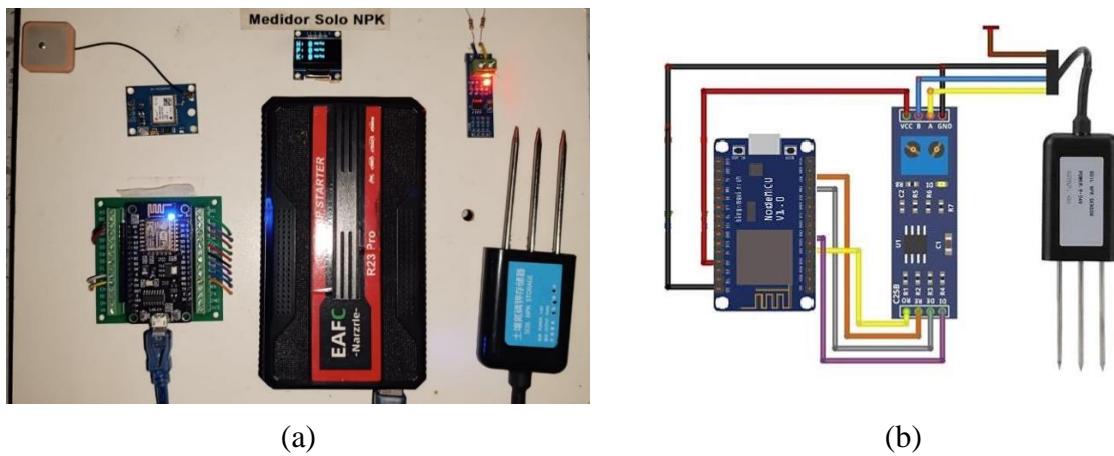
que, o ambiente natural é a fonte direta de dados e o pesquisador, o principal instrumento, uma vez que os dados coletados são predominantemente descritivos

Nesse contexto os níveis de Fósforo e Potássio foram testados, porém, o Nitrogênio foi excluído devido à sua volatilidade e à prática dos laboratórios de não conseguir determinar seus níveis. Segundo QUIMIVITA (2022), o Nitrogênio varia rapidamente no solo, afetando a precisão dos resultados. Nisso o instrumento de análise é parte de um protótipo desenvolvido com dispositivos IoT.

O JXBS-3001 *Soil NPK* é um sensor óptico que detecta gases de NPK no solo e transmite os valores dos micronutrientes. O MAX485 TTL é um módulo conversor que transforma sinais elétricos TTL em entradas RS485 para comunicação com o controlador. O ESP8266 NodeMCU é um microcontrolador com Wi-Fi, usado em projetos de IoT, programável em C++ e com limitações de memória. (MOHAMMED e SANJAY, 2022).

Pode-se observar o protótipo, apresentado na figura 1(a) e seu esquema de componentes na figura 1(b).

Figura 1: Visualização da construção do protótipo (a) e conexões no esquema de componentes (b).



Fonte: elaborado pelo autor.

3.1 Dataset

O *Dataset* foi adquirido por meio de uma fusão entre os dados laboratoriais, fornecidos por um laboratório de análise de solo e a inferência digital, utilizando o protótipo e alternando entre três sensores de medição de NPK (JXCTIOT), contabilizando o total de 96 registros e 4 dimensões.

3.2 Desenvolvimento e validação

Dividido e desenvolvido em quatro etapas: montagem do protótipo e desenvolvimento do código inicial para o sensor de medição de (P) e (K) do solo; aquisição de dados de 8 amostras de solo, gerando 96 registros digitais com dois sensores; identificação de diferenças significativas entre medições e análises laboratoriais; e uso de técnicas de IA para aproximar as leituras digitais das análises laboratoriais.

O algoritmo escolhido para realizar a tarefa de aproximação da diferença foi o DWNN, que recebeu como conjunto de dados as dimensões FÓSFORO SENSOR e POTÁSSIO SENSOR, dados na equação 1:

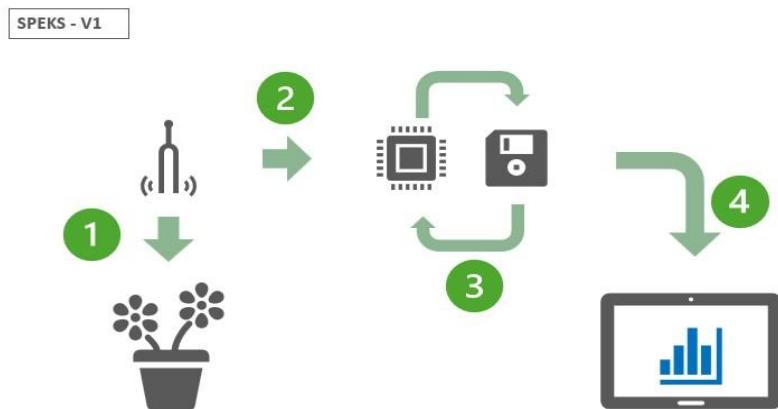
$$X_{sensor} = (P_{sensor}, K_{sensor}), \quad (1)$$

Sendo X_{sensor} , o conjunto pré-processado utilizando o pré-processamento *MinMax*. Os valores de resposta colocam-se as dimensões: FÓSFORO LABORATÓRIO e POTÁSSIO LABORATÓRIO, sendo definido na equação 2, como:

$$Y_{lab} = (P_{lab}, K_{lab}). \quad (2)$$

Para o funcionamento, o sensor é colocado no solo e executa a leitura, figura 2 (1), gera um registro de entradas $X_{sensor,i}$. Na figura 2 (2), utilizando os dados obtidos em X_{sensor} e Y_{lab} é realizado o processamento utilizando o algoritmo DWNN. Por último, apresentado na figura 2(3), foi gerada uma leitura que se aproximou substancialmente a análise gerada por laboratório, como apresentado na figura 2 (4).

Figura2: Fluxograma de funcionamento do protótipo.



Fonte: elaborado pelo autor

Na última etapa de desenvolvimento desse projeto, a avaliação da técnica é feita utilizando os dois modelos. *O 10-Fold Cross-Validation* para atestar a inferência da técnica de regressão utilizando o algoritmo DWNN; e o teste de parametrização, na qual é gerada uma variação de 0,1 para cada $\sigma = 0,1$, até $\sigma = 1$, em busca de um erro menor.

4. RESULTADOS E DISCUSSÃO

Para demonstrar os resultados, inicia-se com os levantamentos a partir das amostras de laboratoriais de 8 amostras distintas representados na tabela 1:

Tabela 1: Discriminação dos resultados de Fósforo e Potássio laboratoriais.

Nº Id Amostra	Fósforo Laboratório	Potássio Laboratório
595	27	94
601	19	70
627	5	102
628	29	125
629	14	133
630	15	344

Fonte: Elaborada pelo Autor.

A medição apresentou uma diferença significativa em relação à análise laboratorial. Para minimizar essa diferença, foram usadas técnicas de IA para treinar os resultados e aproximar a leitura digital da análise laboratorial.

Foram elaboradas amostras do protótipo usando dois sensores distintos, realizando 6(seis) testes por amostra de solo e construindo um *Dataset* com os resultados laboratoriais. Desse modo, algumas divergências entre os resultados laboratoriais e dos sensores foram observadas, os quais foram analisados para obter os valores de erros-padrão usando o método de Erro Absoluto. O Erro Médio Absoluto (MAE) foi calculado entre as variáveis explicadas Y_{lab} (Fósforo Sensor e Fósforo Laboratório) e as variáveis explicativas X_{sensor} (Potássio Sensor e Potássio Laboratório). Empregando a seguinte formula dada pela equação 3:

$$MAE = \frac{\sum_{i=1}^n |dX_{sensor,i} - Y_{lab,i}|}{n}, \quad (3)$$

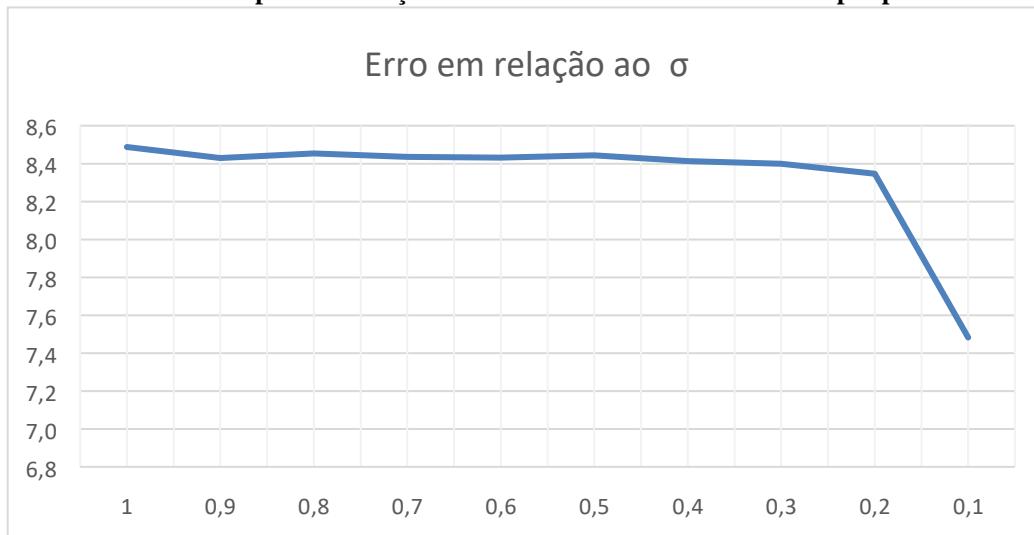
no qual: $X_{sensor,i}$ é o valor sensoriado digitalmente da amostra i ; $Y_{lab,i}$ é o valor extraído por reagentes químicos feitos pelo laboratório da amostra i ; e n é o número total de amostras, neste caso, 96 registros. Desta forma, são somadas a diferença absoluta entre cada linha de dados,

posteriormente são obtidos os valores médios da soma dos erros. Obtendo, assim, um erro médio de 79,60.

Os resultados indicam uma divergência significativa entre as leituras do sensor e as análises laboratoriais, sugerindo uma possível imprecisão do sensor. O protótipo, desenvolvido com código do fabricante, pode ser influenciado por variáveis elétricas. No entanto, o microcontrolador permite a incorporação de técnicas de correção de erros usando algoritmos de IA. Neste trabalho, foi utilizado o DWNN em aprendizado supervisionado, útil quando a proximidade dos dados indica semelhança.

O DWNN (MITCHELL, 1997), é um algoritmo de aprendizado de máquina supervisionado usado para regressão, que encontra os exemplos de treinamento mais próximos. Ele coleta dados do sensor e calcula a distância e o peso dos vizinhos mais próximos. Um teste de parametrização foi realizado para encontrar o melhor (hiper parâmetro σ) para o microcontrolador, variando de $\sigma = 1$ a $\sigma = 0,1$. O teste de *10-Fold Cross-Validation* mostrou que $\sigma = 0,1$ reduziu o erro em quase 1 ponto.

Gráfico 1: Teste de parametrização entre o Erro Médio Absoluto e o hiper parâmetro σ .



Fonte: Elaborada pelo autor.

Por conseguinte, o teste mostrou uma queda acentuada no erro quando $\sigma = 0,1$, tornando esse o valor padrão para o protótipo. O teste de *10-Fold Cross-Validation* com $\sigma = 0,1$ confirmou o erro médio gerado no teste de parametrização, conforme apresentado na tabela 2.

Tabela 2: 10-Fold Cross-Validation do Dataset utilizado com $\sigma = 0, 1$.

Fold	MAE	MAE (P)	MAE(K)	(T)
<i>Fold 1</i>	8,9150	0,6889	8,2262	0,0359
<i>Fold 2</i>	7,4746	0,6568	6,8178	0,0250
<i>Fold 3</i>	6,4505	0,6304	5,8201	0,0209
<i>Fold 4</i>	8,2197	1,0288	7,1909	0,0240
<i>Fold 5</i>	8,4942	0,6976	7,7966	0,0240
<i>Fold 6</i>	8,0827	0,7049	7,3777	0,0229
<i>Fold 7</i>	5,7969	0,7514	5,0455	0,0230
<i>Fold 8</i>	5,7363	0,4775	5,2589	0,0209
<i>Fold 9</i>	6,8668	1,0773	5,7895	0,0260
<i>Fold 10</i>	8,2552	0,5502	7,7051	0,0239
Erro médio	7,4292	0,7264	6,7028	0,0247

Fonte: Elaborada pelo autor.

A diferença entre o erro inicial de 79,60 para 7,42, representa uma aproximação do erro em 10,7 vezes de diferença, sendo o erro atual inferior a 10% em relação ao erro inicial. No caso da leitura do potássio o erro já está em 0,72, o que é um excelente resultado.

5. CONCLUSÃO

A criação do protótipo foi considerada possível, mas no primeiro momento, os resultados das análises de solo mostraram uma diferença significativa entre os dados dos sensores e os valores laboratoriais. O Erro Médio Absoluto (MAE) de 79,60 indica uma precisão relativamente baixa dos sensores em comparação aos métodos convencionais de análise de solo.

A aplicação do algoritmo DWNN melhorou significativamente a precisão, reduzindo o erro médio absoluto em mais de 10 vezes, com um erro inferior a 10%. A leitura do macronutriente potássio foi especialmente precisa, com um erro médio inferior a 1, indicando que a prática é promissora.

Em suma, a dificuldade final foi embarcar a solução de IA no micro controlador devido à sua capacidade de armazenamento limitada. No entanto, com técnicas de otimização, possibilitaram a inclusão do algoritmo e o *Dataset* normalizados. Como trabalho futuro, pretende-se comparar outros métodos de IA que possam ser embarcados no microcontrolador para reduzir ainda mais o erro.

REFERÊNCIAS

- AMARAL, L. R.; COLAÇO, A. F.; MOLIN, J. P. Mapa de produção. 1 ed. color 10cm x10,05 cm. Agricultura de precisão. Cubatão: Oficina de Texto, 2015.
- ASSOCIAÇÃO BRASILEIRA DE AGRICULTURA DE PRECISÃO E DIGITAL. Sobre a Associação Brasileira de Agricultura de Precisão e Digital. 2016. Disponível em:<<https://www.asbraap.org/>>. Acesso: 25.Mar.2024.
- BARICELLO, D. L. Agricultura 5.0: inovações, trajetória da agricultura brasileira e os desafios climáticos. 2023. (Trabalho de Conclusão de Curso). Universidade Federal de Santa Maria (UFSM). Santa Maria. Disponível em:<https://repositorio.ufsm.br/bitstream/handle/1/30906/Barichello_Diana_Luisa_2023_TCC.pdf?sequence=1&isAllowed=y>. Acesso em 01 mai. 2024.
- BELANDI, C. Com alta recorde da agropecuária, PIB fecha 2023 em 2,9%. Agência IBGE Notícias. Rio de Janeiro: 01 mai. 2024. Disponível em:<<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-noticias/noticias/39306-com-alta-recorde-da-agropecuaria-pib-fecha-2023-em-2-9#:~:text=A%20atividade%20Agropecu%C3%A1ria%20cresceu%2015,2%25%20em%20rela%C3%A7%C3%A3o%20a%202022>>. Acesso em: 19.Mar.2024.
- COLAÇO, A. F.; MOLIN, J. P. Agricultura de Precisão. Agricultura de Precisão em Citros Mapeamento de Produtividade e Adubação em Taxas Variáveis. Boletim Temático 01. Piracicaba: Faculdade de São Paulo. p. 12, 2014.
- CRESWEL, J. W. Pesquisa qualitativa e projeto de pesquisa: escolhendo entre 5 abordagens. 2. ed. Porto Alegre: Artmed, 2007.
- ESCOVEDO, T.; KOSHIYAMA, A. Introdução a data science: algoritmos de machine learning e métodos de análise. 1. ed. São Paulo: Casa do Código, 2020.
- FRANK, E.; WITTEN, I. H. Practical machine learning tools and techniques. 2nd ed. New York: Elsevier Science, 2005.
- HARARI, Y. N. Sapiens: História Breve da Humanidade. ed.1. Tradução de Marcantônio. J. Porto Alegre: L & PM. 2013.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Produto Interno Bruto (PIB). Disponível em: <https://www.ibge.gov.br/explica/pib.php>. Acesso em: 21 junho. 2024.
- MALAVOLTA, E. Manual de nutrição mineral de plantas. 1. ed. São Paulo: Agronômica Ceres, 2006.
- MITCHELL, T. M. Machine Learning. 1. st ed. New York: McGraw-Hill, 1997.
- MOHAMMED, M. A.; SANJAY, S. IOT based soil NPK monitor via Asynchronous webserver using NodeMCU. v10 Guwahati: 04 Jul. 2022. International Journal for Research in Applied Science&Engineering Technology. V 10. Disponível em:<<https://www.ijraset.com/research-paper/iot-based-soil-npk-monitor-via-asynchronous-webserver>>. Acesso em: 15 mai. 2024.
- PAULA, B. V. Porque o produtor rural deixa de lucrar quando não faz o “exame” da planta?. InovaTec. Universidade Federal de Santa Maria UFSM. 2023. Disponível em:

<<https://www.ufsm.br/orgaos-suplementares/inovatec/2023/05/08/porque-o-produtor-ruraldeixa-de-lucrar-quando-nao-faz-o-exame-da-planta>>. Acesso em 15.Mar.2024.

QUIMIVITA. 2022. Entenda o que é uma análise de solo e por que o nitrogênio não aparece na mesma. Disponível em: <https://quimivita.com.br/dicas/entenda-o-que-e-uma-analise-desolo-e-por-que-o-nitrogenio-nao-aparece-na-mesma/>. Acesso em: 29.Mar.2024.

RAI, N. Technology Can Boost Crop Yields, Halve Food Prices By 2050. The Wall Street Journal, New York, fevereiro 2014. Disponível em: <<https://www.wsj.com/articles/BL-REB-23171>>. Acesso em: 21 junho 2024.

SILVA, A. C.; SILVA, G.T.S. Avanço da ciência de dados e big data, inteligência artificial, aprendizado de máquina e cooperativas de dados. EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. 2002. Disponível em: <<https://www.embrapa.br/visao-defuturo/agrodigital/sinal-e-tendencia/avanco-da-ciencia-de-dados-e-big-data-inteligenciaartificial-aprendizado-de-maquina-e-cooperativas-de-dados>>. Acesso em 12.05.2024.

SOKOLOVA, L. O que saber sobre agricultura inteligente usando IoT. ForbesAgro. 2021. Disponível em: <https://forbes.com.br/forbesagro/2021/09/o-que-saber-sobre-agriculturainteligente-usando-iot/>. Acesso em 26.Mar.2024.

SOLUM, L. Manual prático de coleta. 2020 Disponível em: <https://www.solumlab.com.br/manual-pratico-de-coleta/>. Acesso em 22.Mar.2024

TERRANALISES. ®Terranalises Laboratório de Análise Ambientais. Como é feita a análise de solo?. 2022. Disponível em: <<https://terranalises.com.br/novidade-detalhes/52/comoe-feita-a-analise-de-solo?>>. Acesso em 21.Mar. 2024.

VASCONCELOS, W. Modelo de indicadores para monitoramento de inovações tecnológicas na agricultura de precisão. 1. ed. São Paulo: Dialética, 2023.