

**CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA “PAULA SOUZA”**

**FACULDADE DE TECNOLOGIA DE BEBEDOURO**

**TECNOLOGIA EM BIG DATA NO AGRONEGÓCIO**

**PROTOTIPAÇÃO DE SENSORIAMENTO EMBARCADO DE  
FÓSFORO E POTÁSSIO NO SOLO - SEPKS**

**AUTOR: RENAN DE JESUS SOUZA**

**ORIENTADOR: RENAN GUILERME NESPOLO**

**BEBEDOURO**

**2024**

RENAN DE JESUS SOUZA

**PROTOTIPAÇÃO DE SENSORIAMENTO  
EMBARCADO DE FÓSFORO E POTÁSSIO NO SOLO -  
SEPKS**

Monografia apresentada à Faculdade de Tecnologia de Bebedouro, como parte dos requisitos para a obtenção do título de Tecnólogo em Big Data no Agronegócio

Orientador: **prof. Me. Renan Guilherme Nespolo**

BEBEDOURO

2024

SOUZA, R. J.. **Avaliação de Acuracidade do Sensor de Medição de Fósforo e Potássio no Solo** . Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 43 p. 2024.

## RESUMO

O agronegócio no Brasil tem crescido significativamente, destacando-se especialmente na produção de soja e milho, sendo um dos principais motores do PIB do país. Em 2023, o PIB brasileiro superou as expectativas, alcançando R\$ 10,9 trilhões, com um crescimento de 15,1% nas atividades agrícolas. O setor enfrenta desafios relacionados à sustentabilidade e produtividade, e as novas tecnologias têm sido fundamentais para superá-los, como destaca DUAIK (2023). A Agricultura 4.0 e a agricultura de precisão, que utilizam drones e sensores, são exemplos de inovações que permitem uma gestão mais eficiente dos recursos. Este estudo visa analisar a precisão de um protótipo de um sensor de solo, comparando seus resultados com análises laboratoriais para verificar sua eficácia na medição de fósforo e potássio no solo. A pesquisa utiliza uma abordagem quantitativa e descritiva, destacando a importância da validação dos dados fornecidos pelos sensores. Resultados preliminares mostram divergências entre as medições do sensor e do laboratório, porém a aplicação de aprendizado de máquina melhorou a precisão das medições, indicando potencial para futuras aplicações e desenvolvimentos.

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

SOUZA, R. J. **Avaliação de Acuracidade do Sensor de Medição de Fósforo e Potássio no Solo** . Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 44 p. 2024.

## ABSTRACT

The agribusiness sector in Brazil has grown significantly, particularly excelling in the production of soybeans and corn, and stands as one of the main drivers of the country's GDP. In 2023, the Brazilian GDP surpassed expectations, reaching R\$ 10.9 trillion, with a 15.1% growth in agricultural activities. The sector faces challenges related to sustainability and productivity, and new technologies have been fundamental in overcoming these challenges, as highlighted by DUAIK (2023). Agriculture 4.0 and precision agriculture, which utilize drones and sensors, are examples of innovations that enable more efficient resource management. This study aims to analyze the accuracy of a soil sensor prototype by comparing its results with laboratory analyses to verify its effectiveness in measuring phosphorus and potassium in the soil. The research adopts a quantitative and descriptive approach, emphasizing the importance of validating the data provided by the sensors. Preliminary results show discrepancies between the sensor and laboratory measurements, but the application of machine learning improved the precision of the measurements, indicating potential for future applications and developments.

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

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>13</b>
<b>2</b>	<b>DESENVOLVIMENTO .....</b>	<b>15</b>
<b>2.1</b>	<b>AGRICULTURA.....</b>	<b>15</b>
<b>2.2</b>	<b>NUTRIÇÃO DE SOLO .....</b>	<b>17</b>
<b>2.3</b>	<b>ANÁLISE DE SOLO .....</b>	<b>19</b>
<b>2.3.1</b>	<b>COLETA DE SOLO .....</b>	<b>20</b>
<b>2.4</b>	<b>MÉTODOS DE ANÁLISE .....</b>	<b>23</b>
<b>2.6</b>	<b>ANÁLISE DE DADOS .....</b>	<b>28</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>33</b>
<b>3.1</b>	<b>MATERIAIS UTILIZADOS.....</b>	<b>33</b>
<b>3.2</b>	<b>DATASET .....</b>	<b>37</b>
<b>3.3</b>	<b>DESENVOLVIMENTO E VALIDAÇÃO .....</b>	<b>37</b>
<b>4</b>	<b>RESULTADOS ESPERADOS.....</b>	<b>40</b>
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>40</b>
	<b>REFERÊNCIAS .....</b>	<b>41</b>
	<b>APÊNDICE.....</b>	<b>48</b>

## LISTA DE FIGURAS

<b>FIGURA 1 - INTERNET NO CAMPO .....</b>	<b>16</b>
<b>FIGURA 2 - MECANISMOS DE ABSORÇÃO .....</b>	<b>17</b>
<b>FIGURA 3 - MAPA PEDOLÓGICO.....</b>	<b>21</b>
<b>FIGURA 4 - FERRAMENTA DE COLETA DE SOLO.....</b>	<b>22</b>
<b>FIGURA 5 - QUADRICICLO EQUIPADO COM TRADO BROCA.....</b>	<b>22</b>
<b>FIGURA 6 - MAPA DE DISTRIBUIÇÃO DE FÓSFORO .....</b>	<b>26</b>
<b>FIGURA 7 - MAPA DE PRODUTIVIDADE .....</b>	<b>27</b>
<b>FIGURA 8 - SENSOR NPK.....</b>	<b>34</b>
<b>FIGURA 9 - MODULO RS485.....</b>	<b>34</b>
<b>FIGURA 10 – ESP8266.....</b>	<b>35</b>
<b>FIGURA 11 - CIRCUITO DO SENSOR DE SOLO NPK.....</b>	<b>36</b>
<b>FIGURA 12 -PROTOTÍPO SPEKS .....</b>	<b>37</b>
<b>FIGURA 13 -COLETA DE DADOS .....</b>	<b>38</b>
<b>FIGURA 14 - EXEMPLO DOS PROCESSOS DO PROTÓTIPO SPEKS.....</b>	<b>39</b>

## Lista de Tabelas

TABELA 1 – ESPECIFICAÇÕES TÉCNICAS ESP8266.....	36
TABELA 2 - DISCRIMINAÇÃO DOS RESULTADOS DE FOSFORO E POTÁSSIO ..... LABORATORIAIS .....	40
TABELA 3 - 10-FOLD-VALIDATION DO DATASET UTILIZADO COM $\sigma = 0,1$ .....	43
TABELA 4 - DISCRIMINAÇÃO DOS RESULTADOS DE FOSFORO E POTÁSSIO DOS E SENSORES E LABORATORIAIS .....	48

## Lista de Gráficos

<b>GRÁFICO 1 - TESTE DE PARAMETRIZAÇÃO ENTRE O ERRO MÉDIO ABSOLUTO E O HIPER PARÂMETRO <math>\sigma</math> .....</b>	<b>41</b>
--	-----------

## Lista de Algoritmos

ALGORITMO DWNN .....	30
----------------------	----

## LISTA DE EQUAÇÕES

EQUAÇÃO 1 - DETERMINAÇÃO DE FÓSFORO .....	23
EQUAÇÃO 2 - PESO ESPECTRAL .....	30
EQUAÇÃO 3 - DISTANCIA EUCLIDIANA .....	30
EQUAÇÃO 4 - FUNÇÃO PRED(W,Y).....	31
EQUAÇÃO 5 - MINMAX.....	31
EQUAÇÃO 6 – APROXIMAÇÃO DE ERROS .....	39
EQUAÇÃO 7 – VALORES DE RESPOSTA.....	39
EQUAÇÃO 8 – MAE .....	40

## Lista de Siglas

$\varphi$  - Fi

$\mu$  - Micro

$\sigma$  - Sigma

$\Sigma$  - Soma

4G - Internet de Quarta Geração

A - Amperes

AP - Agricultura de Precisão

AsBraAP - Associação Brasileira de Agricultura de Precisão e Digital

B - Boro

Ca - Calcio

Cl - Cloro

Cu - Cobre

dm<sup>3</sup> - Decímetro Cúbico

DWNN - *Distance Weighted Nearest Neighbors*

ESP8266 - Microcontrolador

Fe - Ferro

GPIOs - *General Purpose Input/Output*

GPS - *Global Positioning System*

IA - Inteligência Artificial

IoT - *Internet of Things*

K - Potássio

KNN - *K-Nearest Neighbor*

La - Lantânio

MAE - *Mean Absoluto Error*

Mg - Magnésio

mg - Miligramas

MB - Megabytes

MHz - Mega-hertz

ML - *Machine Learning*

MM - Minimax

Mn - Manganês

Mo - Molibdênio

MSE - *Mean Squared Error*

N - Nitrogênio

NPK - Nitrogênio, Fosforo, Potássio

Ni - Níquel

P - Fósforo

pH - Potencial Hidrogeniônico

RS 485 - Meio de Transmissão

S - Enxofre

SEPKS - Sensoriamento Embarcado de Fósforo e Potássio no Solo

V - Volts

Zn – Zinco

## 1 INTRODUÇÃO

O agronegócio no Brasil tem desenvolvido a taxas notáveis, com destaque para os últimos anos, o setor vem suprindo o mercado nacional e contribuindo decisivamente para as exportações, com realce para a soja e milho. Não obstante segundo dados do Instituto Brasileiro de Geografia e Estatísticas (IBGE), o Produto Interno Bruto (PIB) brasileiro fechou 2023 em 2,9% acima das previsões dos especialistas, totalizando R\$ 10,9 trilhões, todo esse resultado positivo se deve principalmente as atividades agrícolas, que por sua vez teve um crescimento de 15,1% e comparação ao ano de 2022 evidenciando sua importância econômica e social no Brasil. (BELANDI, 2024).

O setor vem se moldando para enfrentar os desafios do século XXI, desvios esses com a sustentabilidade e alta produtividade nas lavouras, com intuito produzir mais com economia de recurso. O uso de novas tecnologias tem se tornado um fator relevante como agricultura de precisão no monitoramento avançado, prática inovadora que consiste na utilização de drones e sensores integrados, para coleta de dados detalhado, e análise de informação, para tomadas de decisões eficiente, baseados em dados precisos. Eles permitem o mapeamento detalhado de áreas específicas no campo, permitindo uma intervenção e melhoria com maior exatidão, bem com a otimização dos insumos como, fertilizantes, corretivos, sementes e defensivos DUAIK (2023).

A agricultura de precisão possibilita uma agricultura inteligente ferramentada com o uso de sensores de monitoramento em tempo real do clima, plantas e solo entre outros, proporcionando análises diária do solo desempenhando um papel fundamental na agricultura moderna, já que a base de qualquer colheita saudável e produtiva é a qualidade do solo em que as plantas crescem. Fator determinante na produção de culturas, a quantidade e a disponibilidade adequada de nutrientes, como Fósforo (P) e Potássio (K), são fatores críticos e decisório na saúde das plantas e a produtividade das colheitas.

No entanto esses sensores são uma tecnologia recente no campo, e entender a confiabilidade desses sensores é um fator primordial na utilização desses dispositivos, em especial nos parâmetros de solo. Para cada análise laboratório além de demandar tempo de coleta, transporte e análise; o custo médio de uma análise laboratorial de solo custa entre R\$50,00 e R\$80,00 (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 aprendizado de máquinas para minimizar o erro entre a análise digital e a laboratorial dos macronutrientes, Fósforo (P) e Potássio (K). As principais contribuições do presente trabalho são:

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

O presente trabalho está segmentado em: 1 Introdução; 2 Fundamentação Teórica; Materiais e Métodos; 4 Resultados Esperados; 5 Conclusões; ao final as Referências.

## 2 DESENVOLVIMENTO

Na presente seção são apresentados todos os fundamentos relativos ao presente estudo. A seção está separada nos seguintes tópicos: 2.1 Agricultura; 2.2 Nutrição do Solo; 2.3 Análise de solo; 2.4 Métodos de Análise; 2.5 Agricultura de Precisão; e 2.6 Análise de Dados.

### 2.1 AGRICULTURA

A agricultura permeia o cotidiano humano, estabelecendo-se como uma prática tão intrínseca à sociedade que, por vezes, presume-se erroneamente que a história humana coincidiu com o advento da agricultura. Contudo, uma análise histórica detalhada desvenda uma narrativa distinta, revelando que a domesticação de plantas e animais é um desenvolvimento relativamente recente na trajetória da evolução humana (HARARI, 2013). Porém a evolução nunca foi tão significativa quanto nos últimos anos.

Em 2015 surge o conceito de Agricultura Digital ou 4.0 conceito esse inicializa um nova era que permeia até o período atual, faz a utilização de tecnologia de ponta baseada em conteúdo digital interconectados, com geração de dados por dispositivos de IoT Internet of Things” ou em português, Internet das Coisas, característico da agricultura de precisão, necessitam ser armazenados em nuvem, gerando grande volume de dados com intuito de extrair informações necessária para tomadas de decisões rápidas e mais assertivas, outra das principais característica desse etapa da evolução agrícola e a utilização de dispositivos remotos como drones e tratores autônomos.

Por último a quinta revolução no setor agrícola, intitulada Agricultura 5.0, seu principal objetivo e agrupar todos as técnicas e tecnologias desenvolvidas até o momento, com o uso de Inteligência Artificial (IA) e conectividade no campo, afim de processar e analisar o grande volume de dados com intuito de extrair informações necessária para tomadas de decisões rápidas e mais assertivas, gerando conhecimento com auxiliadora na condução e atuação de máquina autônomas, busca promover uma agricultura do futuro com respostas rápidas mais precisas.

Entre as inovações está estão o uso de drones para monitoramento e aplicação de insumos, sensores para coleta de dados em tempo real, e softwares de gestão, como resultados

do uso correto das tecnologias. Proporciona maior aproveitamento dos recursos, promovendo uma produção mais eficiente e sustentável (BARICHELLO, 2023). Figura 1 ilustra antenas de internet 4G funcionando por meio de energia solar na lavoura em General Salgado (SP), a fim de promover a conectividade no campo.

**Figura 1: Internet no campo.**



Fonte: E. SILVA (2022).

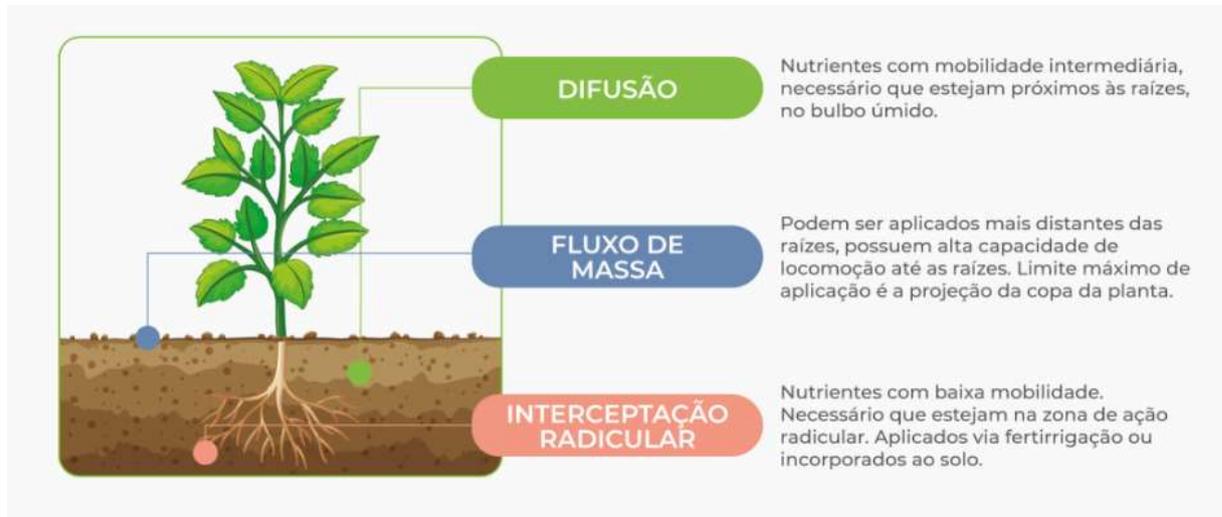
As práticas agrícolas durante a história influenciaram o sucesso ou o fracasso das sociedades ao longo da história, para DIAMOND (2005), desde seu primórdio, a agricultura tem sido um pilar fundamental para o desenvolvimento humano, bem como a sustentação das civilizações, além de promover o sustento humano, mas também instigou mudanças socioeconômicas profundas, catalisando o surgimento de assentamentos estáveis, em detrimento de uma vivência nômade. Essas mudanças por consequência conceberam sociedades complexas fomentando o avanço tecnológico através dos séculos.

## 2.2 NUTRIÇÃO DE SOLO

Para o desenvolvimento de qualquer cultura, a nutrição solo é um aspecto essencial, visto que, um solo rico em nutriente proporciona a planta um crescimento saudável. Neste contexto MALAVOLTA (2006), reitera que uma nutrição correta do solo é substancial para garantir a saúde das plantas e obter uma boa produção agrícola. Os elementos componentes presentes no solo coadjuvam para o crescimento da vegetação, impactando diretamente a qualidade e quantidade da produção agrícola.

Como visto, o solo é o meio que atua como reservatório de minerais necessários às plantas, onde a raiz absorve os elementos por meio do seu sistema radicular obtendo os nutrição necessária, observado seus mecanismos de absorção dos nutrientes, destacam-se três modelos principais de mecanismo de absorção: Fluxo de massa, Interceptação radicular e difusão. A figura 2 exemplifica os tipos de mecanismos de absorção.

**Figura 2: Mecanismos de Absorção**



Fonte: (VITAS, 2024).

- **Difusão:** os nutrientes movem e se concentração para um ponto de menor concentração na superfície da raiz.
- **Fluxo de massa:** os nutrientes são transportados para raiz junto com a movimentação da água, por consequência da transpiração das plantas.
- **Interceptação radicular:** as raízes se desenvolvem, e em, contado com os

nutrientes e os absorvem. (BLOOM E EPSTEIN, 2006).

Em virtude desse processo complexo e vital a vida da lavoura, é diretamente influenciado por diversos fatores do solo como sua composição química, biológica e estrutura física e disponibilidade de micronutrientes e macronutrientes. Os macronutrientes, como, Nitrogênio, Fósforo e Potássio, frequentemente são utilizados em maior quantidade sendo essenciais para o crescimento vegetal, atuando em funções estruturais e metabólicas das plantas, onde compõem partes relevantes das plantas, a exemplo, a clorofila, os ácidos nucleicos e as proteínas (AGRÔNÔMICA, 2018). Como descrito os macronutrientes são de suma relevância para fertilidade do solo, que são:

**Nitrogênio (N):** presente nos aminoácidos, que formam as proteínas, sendo estes considerados a base física da vida. Essas proteínas atuam como enzimas e desempenham uma ampla gama de funções, como a absorção de minerais pelas raízes ou folhas. O (N) compõe a clorofila molécula esta que dá às plantas sua cor verde e que é crucial para a fotossíntese. Importante elemento para crescimento da cultura, sua escassez provoca vulnerabilidade por ataques doenças e pragas, além de provocar clorose que é caracterizado por amarelamento nas folhas.

**Fósforo (P):** protagonista no desenvolvimento radicular, atua também na floração e maturação de frutos e sementes, colabora para a formação de ácidos nucleicos e membranas celulares. O (P) desempenha um papel central na transferência de energia através de ATP Trifosfato de adenosina, gerado na transpiração essencial para processos de energia, absorção dos minerais e transformação de proteínas, sem esse elemento fica inviável a planta executar seus mecanismos de fotossíntese e respiração.

**Potássio (K):** elemento que atua em parceria com o nitrogênio, somente ele proporciona o funcionamento de mais de cinquenta enzimas, fazendo necessário para a produção de açúcares nas folhas, e para o transporte até as raízes e frutos. Plantas bem nutridas de potássio, se mostra mais resistente a estiagem e ao frio, bem como ao ataque de pragas e moléstias. A falta desse nutriente ocasiona a clorose e necrose dos tecidos nas margens de folhar mais velhas.

**Calcio (Ca):** juntamente com o (P) tem grande papel no desenvolvimento das raízes, auxilia na disponibilidade de nutrientes a planta. Usado em grandes quantidades no solo, diminui a toxidade do solo movimentando o alumínio para camadas mais profundas do solo,

outra função importante é a diminuição da acidez do solo, em um manejo de aplicação conhecido como calagem. Sua carência desencadeia atrofiamento e malformação nos frutos, além de solos ácidos.

**Enxofre (S):** existente na composição de todas as proteínas, com atuação desde a fotossíntese, até a fixação do (N) nas raízes de plantas leguminosas como soja e feijão, contribuindo para ativação de enzimas que participam das reações metabólicas importantes. Sua insuficiência provoca clorose em especial em plantas jovens.

**Magnésio (Mg):** presente na molécula de clorofila, compõe uma posição central, funcionando como ativador de enzimas, auxilia na absorção do (P). Sua indisponibilidade na planta motiva e queda prematura de folhas mais velhas. (ALCARDE *et al*, 2008).

### 2.3 ANÁLISE DE SOLO

Com elucidado acima as plantas são inteiramente dependentes dos micronutrientes e macronutrientes, cuja disponibilidade desses elementos é fator crítico para determinar a produtividade de uma lavoura. Portanto a realização de análises no solo se torna uma atividade crucial e determinante para alcançar níveis satisfatórios de produtividade, os dados obtidos dessas análises, norteiam o profissional a ajustes pertinentes na nutrição do solo e na aplicação de calagem, de acordo com a necessidade de cada cultura. Contudo para obtenção do diagnóstico acurado do estado nutricional, se faz necessário o uso de técnica, materiais e equipamentos específicos para essa atividade. (PAULA, 2023).

De acordo com TERRANALISES, (2022) os laboratórios de análise se dotam diversos mecanismo que são utilizados atualmente para compreensão dos dados do nível nutricional do solo, além a obtenção de outras informações como pH, saturação por alumínio, concentração de argila entre outros.

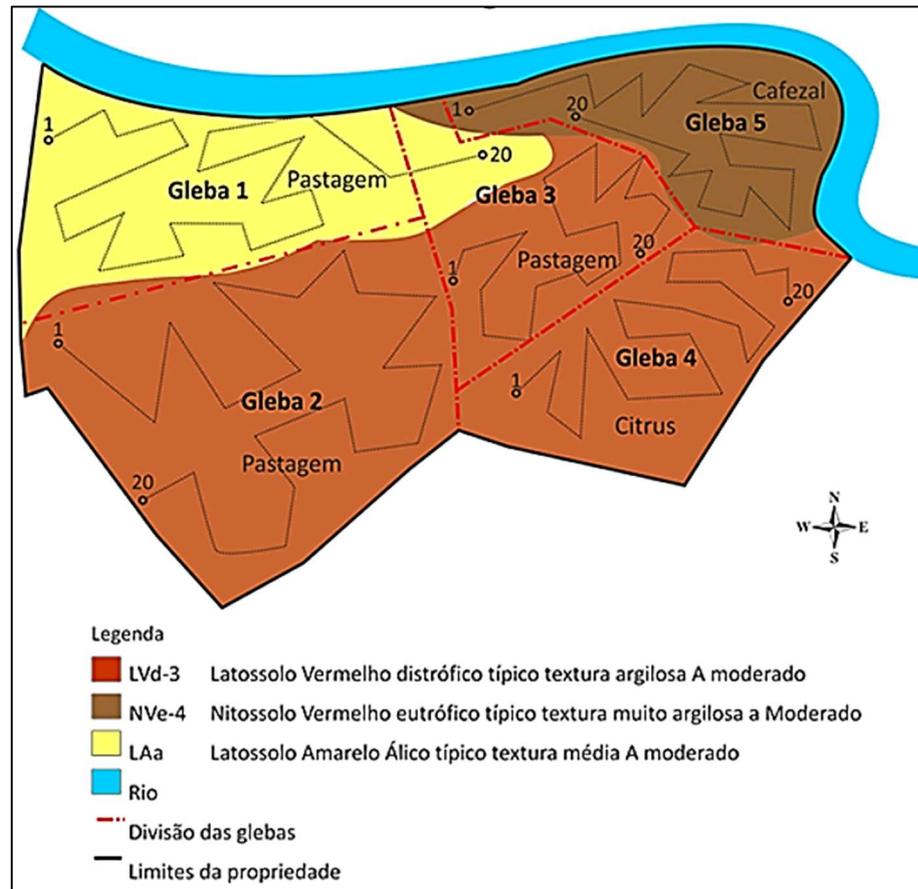
### 2.3.1 COLETA DE SOLO

O processo de análise de solo se inicia na coleta de amostras, fase esta que se torna determinante para obter resultados precisos, pois nesta fase é onde ocorre os maiores níveis de contaminação. De acordo com ORLANDO e RODELLA (1983), entre 80 % e 85 % do erro total nos resultados usados na recomendação de fertilizantes e corretivos pode ser atribuído à amostragem no campo, contudo, na etapa laboratorial apenas 15 % a 20 %. Entretanto, JORGE (1986) explica que em números gerais, dos erros nas amostragens ocorrem na etapa de amostragem, podendo chegar a percentual de 98% dos casos.

O primeiro passo na etapa de coleta de análise, é a realização da divisão do terreno, para que seja feita a coleta das amostras de maneira a transparecer a maior representatividade possível, essas divisões são chamadas de glebas, podendo ser delimitada por diferentes parâmetros de acordo com a textura, coloração, relevo, vegetação, adubação, calagem, entre outras classificações. Além dos parâmetros, há também a exigência de alguns aspectos que são necessários no local do terreno, com estar limpo, livre de pedras, capim, com distância razoável de cupinzeiro, formigueiro e livre de galhos, fezes queimadas entre outros materiais que não representam de forma uniforme o terreno.

Assim percorrendo o terreno em zigue-zague, formando assim um mapa pedológico. A figura 3 ilustra as diferentes glebas, considerando os diferentes tipos de texturas e culturas em uma área.

**Figura 3: Mapa pedológico.**



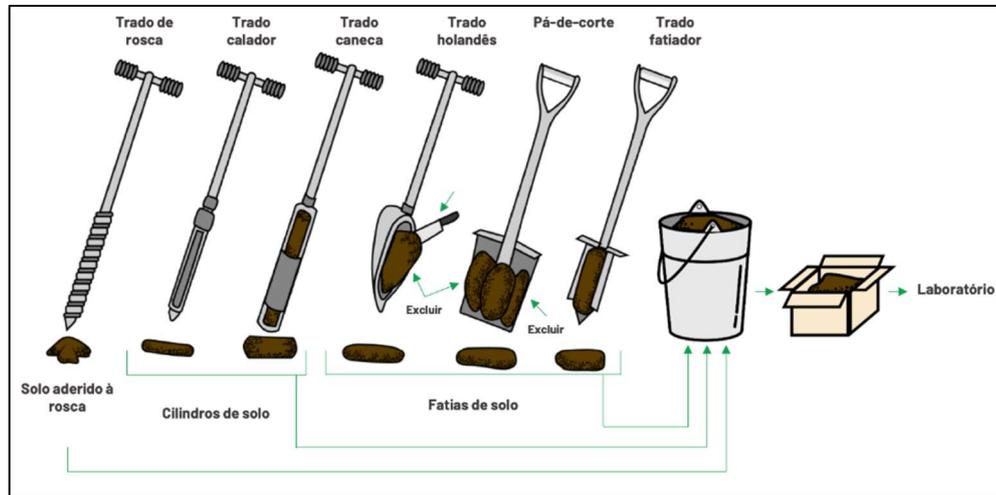
Fonte: (PRADO, 2022).

Após a determinação das glebas se inicia a coleta das amostras com uso de ferramentas como, trados (de rosca, calador, caneca, holandês, fatiador) e pá-de-corte, também, se utiliza de equipamentos mais tecnológicos, como a coleta mecanizadas que faz utilização de uma broca acoplada em microtratores, introduzindo a ferramenta no solo de maneira mecanizada. Com objetivo de alcançar profundidade de 17 a 20 centímetros, o profissional retira a a fermenta do solo sem fazer o movimento de giro ou torção, trazendo consigo a porção de terra. Logo a pós deve ser alocada em um saco plástico ou no balde, devidamente identificado com informações relevantes, com localização, nome da propriedade número da amostra, data, cultura existente e tipo de relevo.

Esses métodos acima de enquadra no tipo de amostra simples, contudo existem também a amostra composta que consiste na mistura homogenia de várias amostras simples, secadas sombras, no qual é retida uma única amostra de cerca de 500gr de terra, identificada

igualmente com as amostras simples. A figura 4 demonstra os instrumentos manuais para coleta de solo mais difundidos na agricultura.

**Figura 4: Ferramenta de coleta de solo.**



Fonte: (SOLUM, 2020).

Além das ferramentas manuais, outros tipos de dispositivos mais robusto são utilizados na agricultura para a cobertura de grandes áreas com demonstrado na figura 5. Além da vantagem proporcionado pela mecanização, como a diminuindo o esforço físico, diversos desses equipamentos são vendidos com tecnologia GPS embarcada, facilitando na identificação da localização das amostras.

**Figura 5: Quadriciclo equipado com trado broca**



Fonte: AGROPRECISION (2022).

## 2.4 MÉTODOS DE ANÁLISE

Há muitos métodos analíticos são utilizados por laboratórios para realizar análises químicas do solo e avaliar sua fertilidade. Entre esses métodos existem três classificações principais a disposição para execução de análises químicas: Fator Intensidade, consistem em técnicas que medem a concentração de nutrientes na solução do solo; Fator Quantidade, que abordam métodos quantitativos são utilizados para determinar a quantidade de nutrientes presentes no solo sólido em equilíbrio com elemento em solução; e Fator de Intensidade e Quantidade, que analisam a fração sólida do solo é possível prever a disponibilidade de nutrientes em médio e longo prazo (TERRANALISES, 2022).

Como visto a diversas técnicas e métodos de análise, para determinar os mais variados parâmetros de pH, textura, macro e micronutrientes no solo. Ao examinar dois macro elementos em especial (P) e (K), são detalhadas apenas as técnicas para obter os resultados relacionadas a estes:

Para o **Fósforo**, se acordo com DONAGEMMA et al (2017) para medir a quantidade de fósforo disponível no solo, utiliza-se uma solução ácida para extrair o fósforo da amostra de solo, seguida de uma reação com uma solução de molibdato de amônio para formar um complexo azul. Faz utilização de uma amostra de 10mg de solo, o procedimento inclui agitação, decantação, e posteriormente exige a leitura da densidade ótica, e da absorbância da solução. Após os processos e métodos químicos das amostras de fósforos, faz a utilização da seguinte equação 1:

$$P = ((L - b))/a \times d \times 10, \quad (1)$$

em que:  $P$ , é a concentração de Fósforo disponível em mg kg<sup>-1</sup> no solo.;  $L$ , a leitura da amostra, em absorbância;  $a$ , o Coeficiente Angular da reta dos padrões (intercepto);  $b$ , o coeficiente linear da reta dos padrões;  $d$ , o fator de diluição do extrato da Solução extratora (se não for necessária a diluição, considerar  $d = 1$ ); e 10, fator que leva em consideração a diluição solo: extrator.

A seguir é feita a determinação da uma curva padrão, que envolve a preparação de soluções padrão diluídas, às quais se adiciona uma solução ácida de molibdato de amônio e ácido ascórbico. As leituras de absorbância são registradas para cada padrão e utilizadas para

traçar um gráfico de concentração versus absorvância. No entanto há recomendações de leitura conforme da escolha do extrator e variações no método dependendo dos equipamentos utilizados.

Para determinar os níveis de Potássio no solo, JOÃO ANDRADE et al (2001) descreve uma das técnicas que se utiliza da resina trocadora de íons, que se inicia com o tratamento da resina em um a solução de bicarbonato de sódio para saturação, a próxima etapa passa por lavagem para remoção dos sais, em seguida a amostra é misturada com água, onde a mistura é agitada e filtrada.

Em sequência é misturada uma solução de lantânio elemento de sigla ( La ), com isso as amostras são lidas no espectrofotômetro, ou podem ser misturas a com a solução de Molibdato para uma leitura no fotocolorímetro (é um instrumento utilizado para medir a concentração de diferentes substâncias em uma amostra, geralmente líquida) chegando assim aos resultados volume de nutrientes este processo pode ser usado também a determinação dos valores de outro nutrientes como cálcio, magnésio, e até mesmo fósforo.

Em geral os valores são apresentados em (mg/dm<sup>3</sup>) que significa os miligramas presentes em decímetro cúbico de terra, que em termos gerais, representa N miligramas de nutriente presente no volume de 1 litro de solo. Vale destacar que os métodos descritos acima não são os únicos instrumentos para determinação dos níveis de nutrição do solo no país.

## **2.5 AGRICULTURA DE PRECISÃO**

O termo denominado Agricultura de Precisão (AP) é discutido a pelo menos 25 anos, de acordo com AMARAL et. al com a expansão territorial da agricultura, promovida principalmente pelo advento da mecanização, permitiu que áreas cada vez maiores fossem cultivadas, ocasionando por consequência na necessidade da distinção de diferentes solos e relevos na mesma propriedade, sendo assim grandes áreas passaram a ser geridas sobre o preceito de desuniformidade dos terrenos.

Diante da necessidade de dar um novo foco a cada composição destinta da lavoura, surgiu a atual agricultura de precisão. Além de proposta de mudança no manejo nas fazendas, a adoção de novas tecnologias, traz consigo as principais características do surgimento da AP.

A AP possui enorme relevância para a agricultura e sociedade, segundo uma pesquisa do International Food Policy Research Institute [IFRI], (2020), a utilização de novas tecnologias no agronegócio, podem aumentar os rendimentos das safras em até 67% e proporcionar a redução dos preços pela metade até 2050.

A Agricultura de Precisão pode ter definições divergentes dependendo da disciplina ou ponto de vista, nos seus primórdios era geralmente associada e chegada de sistemas de GPS no campo, o que por sua vez é uma visão equivocada, pois não é o único fator característico dessa nova agricultura. Ela evoluiu com o objetivo de promover uma gestão mais detalhada a considerar devidamente a variabilidade intrínseca de cada variação de espaço e tempo na lavoura.

Assim para VASCONCELOS (2023), AP se diferencia do manejo convencional devido à eficácia do gerenciamento da variação espacial permitindo aos agricultores o mapeamento dos aspectos da produção agrícola de maneira detalhada por pequenas áreas, contribuindo para uma maior eficiência no uso de recursos, resultando em maior rentabilidade, produtividade e uma agricultura mais sustentável, visto que suas técnicas e tecnologias otimizam principalmente o uso de defensivos agrícolas.

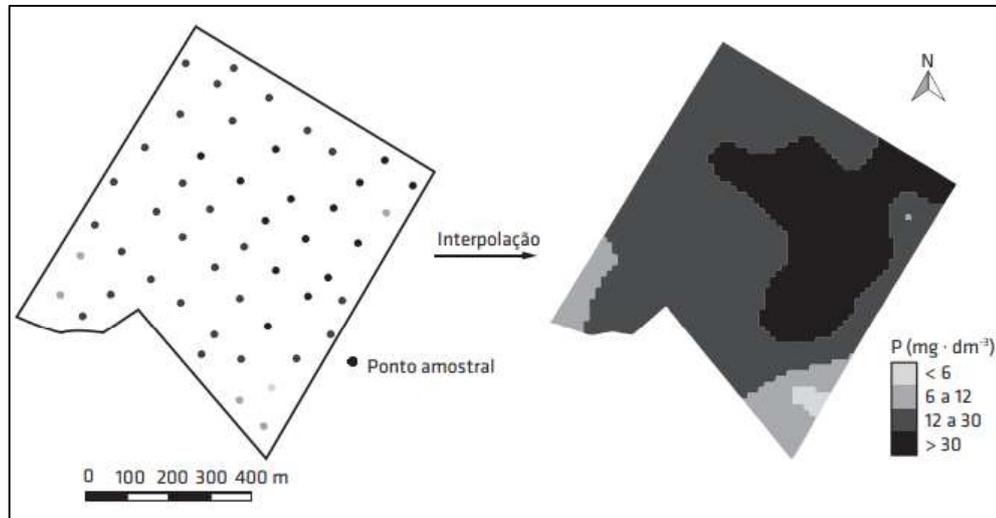
Conforme a Associação Brasileira de Agricultura de Precisão e Digital (AsBraAP) adota uma definição para AP que estabelece que ela se trata “como o conjunto amplo de técnicas e tecnologias que permitem o gerenciamento agrícola baseado na variabilidade espacial e temporal das unidades produtivas visando o aumento de retorno econômico e à redução do impacto ao ambiente.” (ASBRAAP, 2016).

A AP incorpora uma gama de tecnologias inovadoras que são fundamentais para a otimização da produção agrícola. Dentre essas, destacam-se sistema de navegação global por satélites, sensoriamento, automações de máquinas, e IoT entre outras que serão descritas a como:

A Amostragem Georreferenciadas é uma técnica determina que as amostra para análise sejam georreferenciadas, visando não somente a aquisição dos valores nutricionais do solo, mas também elaboração de mapas detalhados que ilustram as variações do terreno. Estes mapas possuem papel vital para tomadas de decisão, compilando dados relevantes, dos níveis de macro e micronutrientes, assim como texturas, pH, e outros aspectos físicos e químicos do solo. A

figura 6 demonstra um mapa distribuição de fósforo após a interpolação dos dados amostrais georreferenciados.

**Figura 6: Mapa de distribuição de Fósforo.**

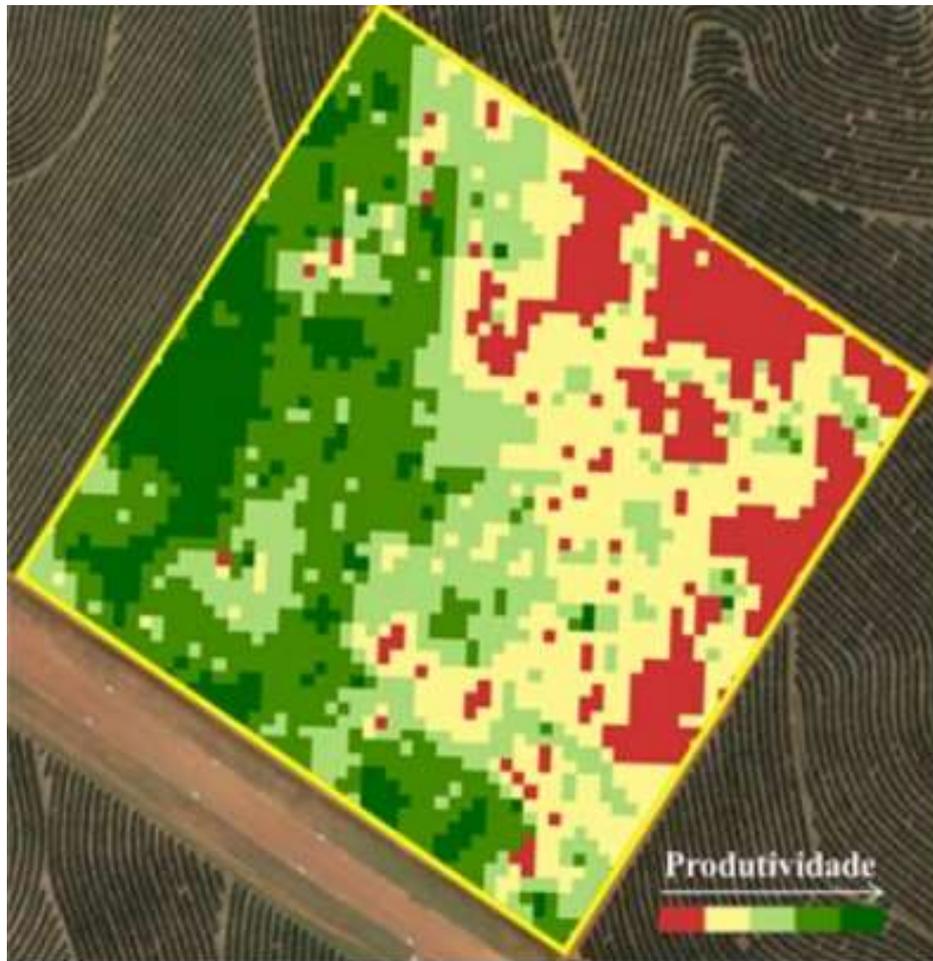


Fonte: (Amaral et al 2015).

Note que este mapa permite uma análise de fácil entendimento da variabilidade dos níveis de (P) no terreno, permitindo ações de correção em áreas com maior carência.

O Mapa de produtividade é uma representação visual que ilustra a variação da produção agrícola em áreas distintas de uma lavoura, com o auxílio de GPS e sensores de campo, permite uma análise com grande relevância para tomadas de decisão. A figura 7 ilustra a produtividade de diversos pomares de laranja mapeada, apresentaram significativa variabilidade espacial da produtividade

**Figura 7: Mapa de Produtividade.**



Fonte: (COLAÇO & MOLIN, 2014).

Os Sensores de Campo tornam possível o monitoramento de planta e solo, sua vantagem é advindo da sua capacidade de coleta um volume grande de dados dentro da mesma lavoura, produzindo informações de variabilidade espacial da área, esses sensores são dispositivos que reagem a estímulos físicos ou químicos de maneira específica e mensurável, fornecendo dados geralmente de forma indireta, colaborando para análise do perfil da lavoura. (COLAÇO e MOLIN, 2014).

O uso de sensores inteligentes, na agricultura apoiam o produtor no monitoramento do ciclo de vida e das condições ambientais da lavoura em tempo real, segundo SOKOLOVA, (2021), o objetivo primordial na coleta de dados, esses dispositivos permitem a construção de conhecimento sobre aspectos geoespacial, tornado possíveis identificar padrões que norteiam ações mais assertivas.

Esses dispositivos interconectados forma um ecossistema, equipamentos como drones e estações meteorológicas, supervisionam e criam alertas sobre o clima, solo, plantas, equipamentos, insumos, proporcionado facilidade no gerenciamento, e ganhos significativos na produção, e na economia de recursos e tempo, gerando dados para análise estáticas, e aprendizado de máquina, a fim de promover cálculos elaborados que tornando dados em conhecimento prático para análise de dados.

## 2.6 ANÁLISE DE DADOS

Com toda essa evolução no campo com sensoriamento nos mais diversos aspectos das atividades agrícolas, sendo empregados em animais, plantas, equipamentos, clima, água, solo entre outros, promovem por consequência um elevado volume de dados a serem processados e tratados para serem transformados em informação que determinas decisões importantes a lavoura

Neste aspecto A. SILVA & G. SILVA (2022) apontam que a disseminação da conectividade no campo, e o crescente volume de dados produzidos no agronegócio necessitam de sistemas integrados, nos últimos anos, o número de plataformas digitais que geram dados continua a crescer. Com a demanda exponencial de geração de dados, com o uso de tecnologia e métodos como Big Data, modelos preditivos, ciência de dados e análise de dados estão promovendo otimização, proporcionando às empresas e produtores novos conhecimentos que vão além das tendências e diagramas.

No meio rural, soluções eficientes geradas por ferramentas como IoT, Aprendizado de Máquina, Big Data, IA (Inteligência Artificial), blockchain e outras aplicações são usadas em implementos, sensores, aplicativos, softwares, tratores, implementos e colheitadeiras cada vez mais sofisticadas.

Como exposto, análise de é um fator determinado atualmente para as propriedades agrícolas, modelos de preditivos e estáticos com utilização para obtenção de informações, há diversos modelos de aprendizagem de máquina para tratamentos dos dados, a avaliação de um modelo de regressão é elaborada por meio de valores preditos pelo modelo.

### 2.6.1 REGRESSÃO

No Aprendizado de Máquina, desempenha um papel crucial em ciência de dados, segundo ESCOVEDO e KOSHIYAMA (2020), essa ferramenta possui relevantes aplicações significativas em várias áreas, suas aplicações, subconjunto da IA permite o aprendizado e o aperfeiçoamento de sistemas com base em dados, fundamentado três diferentes abordagens de aprendizado, que são: Não Supervisionado, Semissupervisionado e Supervisionada, sendo esta última divididas em duas tarefas principais: Previsão ou Classificação.

Enquanto a classificação se concentra em segmentar classes entre os exemplos, a regressão cumpre a tarefa de estimar de um valor contínuo para uma observação dada, um algoritmo de regressão pode ter utilização a exemplo, na previsão de demanda no abastecimento de uma cadeia de suprimentos, a partir dos históricos de consumo.

A técnica de Regressão permite a utilização de vários modelos e algoritmos para a realização do aprendizado. Dentre eles o DWNN (Distance Weighted Nearest Neighbors) se caracteriza como um algoritmo leve que pode ser embarcado em um dispositivo de pouca memória de armazenamento.

O DWNN é um algoritmo de classificação supervisionada, refinado a partir do método dos k-vizinhos mais próximos (KNN), aplica a ponderação a cada peso dos vizinhos mais próximos com base na distância entre o ponto de consulta e os pontos de treinamento. Assim no algoritmo DWNN utilização de função de valor discreto para ponderar o voto de cada vizinho de acordo com o inverso do quadrado de sua distância (MITCHELL, 1997). O DWNN avança o KNN com precisão aplicada aos pesos inversos ao quadrado da distância considerada, influenciando os vizinhos conforme sua proximidade, o algoritmo é apresentado no Algoritmo 1 abaixo:

---

**Algoritmo 1: DWNN**


---

**Entrada:**  $X, y, \varphi, \sigma$

**Saída:**  $\hat{y}$

```

1   $w \leftarrow \text{iniciar}()$ 
2  for  $i$  in  $w$ :
3   $x \leftarrow X_i$ 
4   $w_i \leftarrow \text{rbf}(\varphi, x, \sigma)$ 
5   $\hat{y} \leftarrow \text{pred}(w, y)$ 

```

---

Como apresentado acima as entradas do algoritmo DWNN são:  $X$ , definido como a matriz de características do conjunto de dados de treinamento, na qual, cada linha representa um ponto de treinamento e cada coluna representa uma dimensão;  $y$ , dado como vetor de valores alvo dos pontos de treinamento;  $\varphi$ , sendo esse o ponto de consulta para o qual se deseja realizar a predição; e  $\sigma$  o hiper parâmetro da função de peso espectral. Na saída é retornada a previsão, definida por  $\hat{y}$ , de acordo com os parâmetros recebidos como entradas.

Na linha 1 é iniciado o vetor de pesos, definido por  $w$ . Nas linhas 2 a 4 os pesos são gerados utilizando a função dada na linha 4. Na linha dois a variável  $x$  assume todos os valores de exemplo de treinamento definido por  $X_i$ , sendo  $i$  definido como um índice de linhas em uma representação matricial do conjunto de treinamento  $X$ . A linha 4 define a geração dos pesos do vetor de pesos  $w$ , utilizando a função  $\text{rbf}(\varphi, x, \sigma)$ , função essa definida na equação 2:

$$\text{rbf}(\varphi, x, \sigma) = e^{-\frac{d(x, \varphi)^2}{2\sigma^2}}, \quad (2)$$

sendo  $d(x, \varphi)$  a distância euclidiana entre o exemplo  $x$  e o ponto de consulta  $\varphi$ , definido na equação 3:

$$d(\varphi, x) = \sqrt{\sum_{i=1}^n (x_i - \varphi_i)^2}. \quad (3)$$

Por último na linha 5 é realizada a previsão atribuída em  $\hat{y}$ , em que a função  $pred(w, y)$  é definida na equação 4:

$$pred(\varphi, x, \sigma) = \sum_{i=0}^n \frac{w \cdot y}{w}. \quad (4)$$

## 2.6.2 AVALIAÇÃO E PRÉ-PROCESSAMENTO

Para a avaliação de aprendizado utilizando Regressão como técnica, são usadas comumente as métricas: Erro Médio Absoluto (MAE) e Erro Quadrático Médio (MSE).

O Erro Médio Absoluto (MAE - Mean Absolute Error) mede a média absoluta dos erros de previsão, caso valor de MAE resultante for igual a 10,01 m, por exemplo, este resultado significa que o modelo pode estar errando em média 10,01 m para mais quanto para menos em relação ao valor correto. Assim, para obter uma previsão futura, este resultado precisa ser levado em consideração para a tomada de decisão, sendo usada com frequência em problemas de regressão.

Para o Erro Quadrático Médio (MSE) a média dos quadrados dos erros de previsão é avaliada, portanto, quanto maior é o valor de MSE, significa que o modelo não performou bem em relação as previsões usadas em problemas de regressão. (BARTH, 2023).

Além de todos esses cuidados como o uso de técnica e as métricas de avaliação é necessário muitas vezes pré-processar os valores da variável explicativa. Existem muitos métodos de pré-processamento, tais como: Standard Scaller, Max Absolute e Minmax (GUIMARÃES et al, 2019), este último adotado em nosso estudo.

De acordo com LIU et al (2011), o Minmax é usado para redimensionar valores de dados para um intervalo específico, geralmente [0, 1] ou [-1, 1] por meio da fórmula é usada para a normalização aplicada em pré-processamento de dados os normalizando os valores para que estejam dentro do intervalo especificados, representada na equação 5:

$$\left[ Z_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right], \quad (5)$$

sendo  $x$  representa os valores dos dados;  $x_{\min}$ , o valor mínimo entre todo o conjunto de dados; e  $x_{\max}$  o valor máximo entre todos os elementos no conjunto de dados.

Um segundo método de avaliação muito utilizado para validação é a técnica de *Cross-Validation*. Este, executa sua função repartindo os dados em conjuntos, onde parte é utilizado para treino e a outra parte para avaliação, entre métodos de avaliação está o 10-Fold-Cross-Validation.

Para FRANK e WITTEN (2005) o *10-Fold-Cross-Validation* ou *N-Fold-Cross-Validation* é a forma padrão de medir a taxa de erro de um esquema de aprendizagem em um conjunto de dados específico, para resultados confiáveis, utilizando validação cruzada.

Segundo o autor a validação cruzada deixar um de fora é simplesmente uma validação, onde  $n$  é o número de instâncias no conjunto de dados, cada instância, por sua vez, é deixada de fora e o método de aprendizagem é treinado em todas as instâncias restantes.

É julgado pela sua correção na instância restante, um ou zero para sucesso ou fracasso, respectivamente, assim é calculada a média dos resultados de todos os  $n$  julgamentos, um para cada membro do conjunto de dados, e essa média representa a estimativa final do erro.

### **3 MATERIAIS E MÉTODOS**

Na presente seção são apresentadas todas as etapas de desenvolvimento do protótipo, desde as escolhas de equipamentos até os algoritmos utilizados. Esta seção está segmentada nos seguintes tópicos: 3.1 Materiais Utilizados; 3.2 Dataset; e 3.3 Desenvolvimento e Validação.

#### **3.1 MATERIAIS UTILIZADOS**

A metodologia adotada neste estudo caracteriza-se por ser uma pesquisa descritiva com uma abordagem quantitativa, operacionalizada por meio da análise de dados coletados.

Ao discutir as características da pesquisa qualitativa, CRESWEL (2007) chama atenção para o fato de que, na perspectiva quantitativa, o ambiente natural é a fonte direta de dados e o pesquisador, o principal instrumento, sendo que os dados coletados são predominantemente descritivos.

Em resumo, a pesquisa quantitativa valoriza a riqueza dos detalhes, e o aprofundamento no ambiente natural e a interpretação cuidadosa dos dados coletados. Neste mesmo contexto ANDRADE et al, (2020), aborda a visão em que na pesquisa quantitativa, os objetos estudados são tratados estatisticamente, e sua amostragem significativa em relação com a totalidade, fornecendo dados mais precisos numericamente, em relação ao objeto.

Para este estudo serão testados os níveis de dois macros nutrientes Fósforo e Potássio, ficando de fora a análise dos níveis de Nitrogênio, visto que, este elemento não é de prática os laboratórios determinar os seus níveis devido a sua volatilidade. De acordo com QUIMIVITA (2022), o Nitrogênio está diretamente associado a microrganismos, e a quantidade de nitrato e amônio, as duas formas do nitrogênio no solo, pode variar em questão de minutos, comprometendo assim a precisão dos resultados. Em geral as propriedades fazem uso deste insumo, disponibilizando nos terrenos os valores totais que a lavoura necessita.

O instrumento de análise faz parte de um protótipo desenvolvido por meio de dispositivos IoT, construído pelos alunos do curso de Big Data no Agronegócio da Faculdade de Tecnologia de São Paulo em Bebedouro (FATEC – Jorge Caram Sabbag) composto pelos seguintes componentes:

**JXBS-3001 Soil NPK:** Este componente desempenha o papel de sensor de detecção elétrica óptica é usado para identificar gases de NPK no solo, a partir dessa leitura ele transmite os valores identificados de cada micronutriente, fabricado na China pela empresa JXCTIOT em Weihai, o sensor JXBS-3001 Soil NPK, afere os níveis de gases com respostas rápidas a partir de hastes de aço resistente a corrosão. Demonstrado na figura 8.

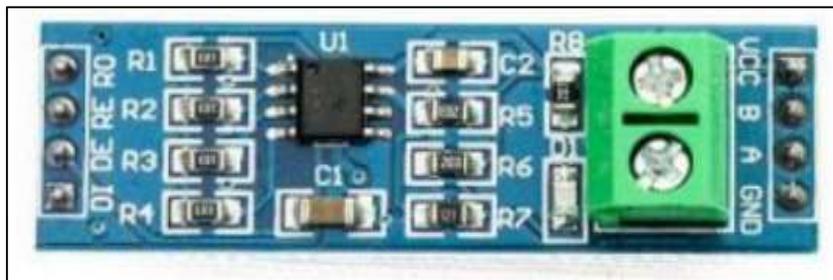
**Figura 8: Sensor NPK.**



Fonte: MOHAMMED & SANJAY (2022).

**Modulo conversor para MAX485 TTL para RS485:** Com o uso de transmissão half-duplex, a unidade conversora MAX485 TTL converte os sinais elétricos TTL para entradas RS485, promovendo a comunicação com o controlador, ilustrado na figura 9.

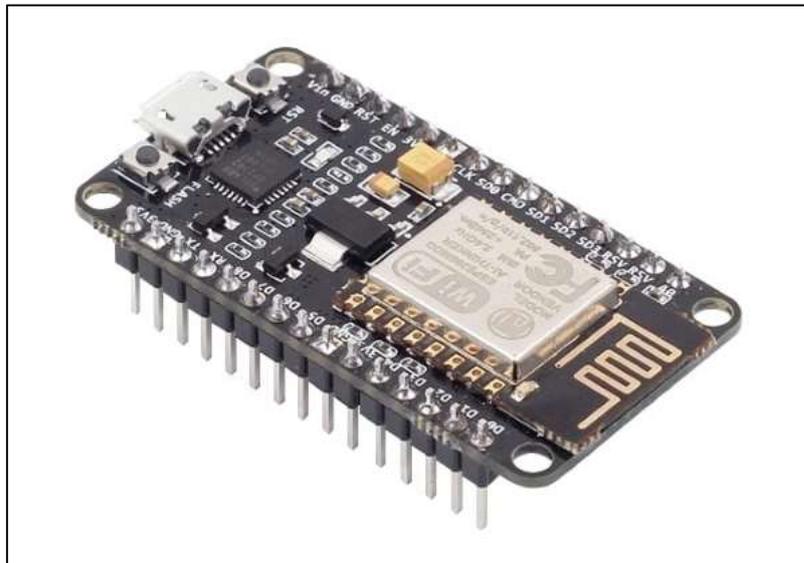
**Figura 9: Modulo RS485.**



Fonte: MOHAMMED E SANJAY (2022).

**ESP8266 NodeMCU:** circuito integrado caracterizado como Microcontrolador com capacidade de se conectar à internet por meio do Wi-Fi permitindo transferência rápida de dados. Equipado com o chip CH340 o torna extremamente confiável, sendo utilizados em setores industriais, Ele é amplamente utilizado em projetos de Internet das Coisas. Ele pode ser programado usando linguagem Arduino e é amplamente utilizado na comunidade maker, oferecendo possibilidade de vincular diversos sensores, contudo este microcontrolador tem limitações quanto a disponibilidade de memória. (MOHAMMED e SANJAY, 2022). A figura 10 demonstra o último componente.

**Figura 10: ESP8266.**



Fonte: (MOHAMMED & SANJAY, 2022).

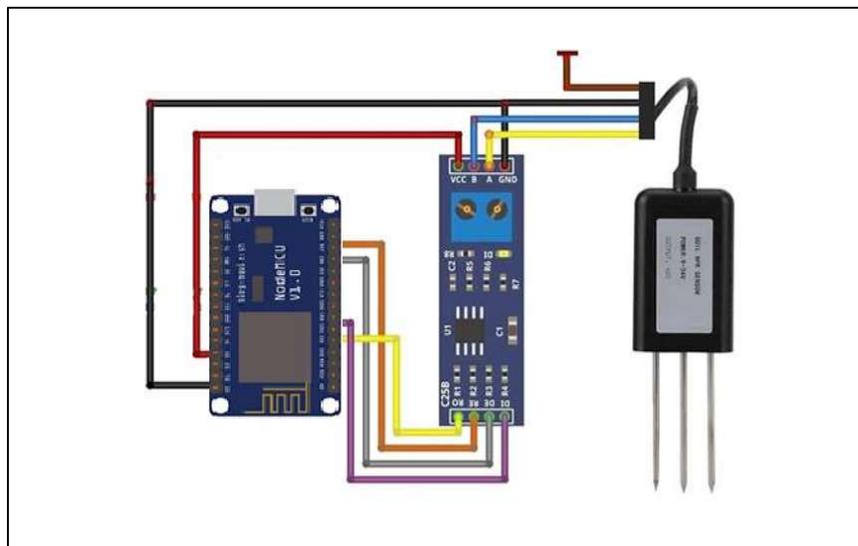
De acordo com LIMA (2023) ESP8266 é uma escolha versátil como plataforma de prototipagem para o projeto foi baseada devido a sua facilidade de programação e conectividade Wi-Fi integrada, tornando-se um dispositivo ideal para projetos de IoT e outras aplicações que exigem comunicação e processamento dados. A tabela 1 demonstras as especificações técnicas do microcontrolador.

**Tabela 1: Especificações Técnicas ESP8266.**

Característica	Especificação
VOLTAGEM	3.3V
Consumo de Corrente	10 $\mu$ A
Memória Flash	16MB max (512k normal)
Processador	Tensilica L106 32 bit
Velocidade do processador	80-160MHz
GPIOs	17(multiplexada com outras funções)
RAM	32K + 80K

Fonte: (Oliveira, 2017)

Após a junções de todos os componentes listados acima podemos observar o protótipo ilustrando seu esquema na figura 11.

**Figura 11: Circuito do sensor de solo NPK.**

Fonte: elaborado pelo autor.

Os dados para os testes, serão provenientes de análises de solo fornecidos por um laboratório de Solo e Tecido Vegetal, essas análises já foram processadas e determinado os valores de acordo com métodos laboratoriais de análise previamente. A partir dessas amostras, o sensor de solo NPK irá medir a disponibilidade desses nutrientes, e posteriormente

correlacionado os valores de ambos. De maneira que os dados obtidos serão comparados com os resultados de análises equivalentes realizadas em um laboratório agrícola especializado, visando validar a precisão e eficácia do dispositivo.

### 3.2 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 alternando entre três sensores de medição de NPK (JXCTIOT), contabilizando o total de 96 registros e 4 dimensões, como apresentado na sessão de Apêndice.

### 3.3 DESENVOLVIMENTO E VALIDAÇÃO

O desenvolvimento foi realizado em quatro etapas diferentes sendo elas: Montagem do protótipo; Aquisição dos dados; Desenvolvimento da solução e a Avaliação da Técnica.

Na etapa de Montagem do protótipo, foi realizada a montagem do protótipo, apresentado na figura 12 e a aquisição do código inicial para o correto funcionamento do sensor de medição do (P) e (K) do solo.

**Figura 12: Protótipo SPEKS.**

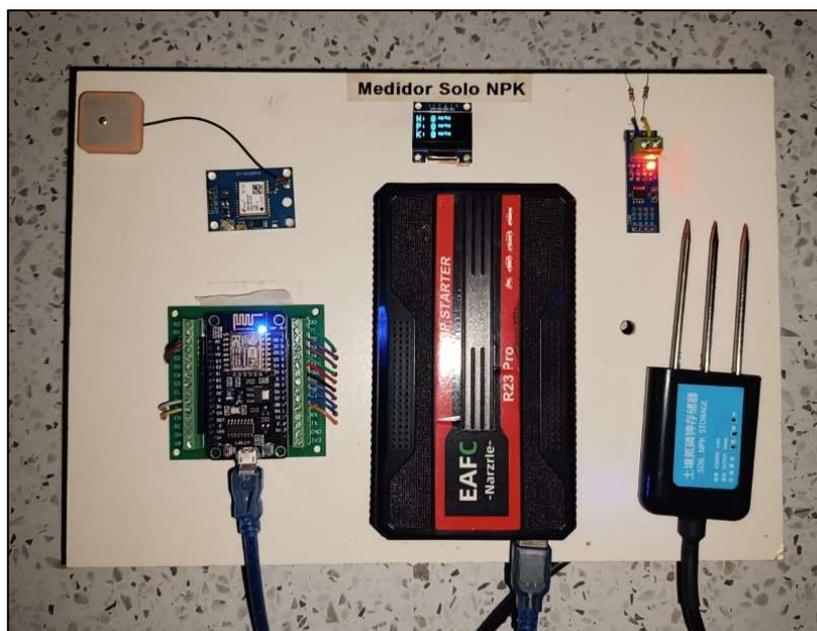


Figura 12 Elaborado pelo autor.

A segunda etapa foi adquirir dados que fossem comprovadamente corretos para analisar como era o comportamento do sensor digital. Como o consórcio da FATEC, com o laboratório de análises de solo, onde realiza essas análises periodicamente, foi cedida 8 amostras para que pudéssemos testar. Utilizando dois sensores diferentes foi possível gerar 96 registros de amostra de solo sensoriadas digitalmente como apresentada na seção 3.2.

A medição apresentou um erro bastante acentuado em relação a análise laboratorial, como apresentado na seção Apêndice. Desse modo como foi definido o erro, a possibilidade de minimizar o erro se tornou viável utilizando técnicas de Aprendizado de Máquinas para treinar os resultados e realizar a aproximação da leitura digital com a análise laboratorial.

**Figura 13: Coleta de macro elementos no solo.**



Fonte: Elaborado pelo autor.

Nessa etapa é iniciada a parte de Desenvolvimento da Solução. Inicialmente a idealização do projeto constitui-se em utilizar uma rede neural (NN) como solução para aproximar o erro entre as duas leituras. Porém o conjunto de dados pequeno acusou o não aprendizado da rede por não ter dados suficientes para garantir o aprendizado da rede neural. Por ter poucos dados e não conter classes ((P) e (K) são valores de leitura), a técnica de regressão se encaixa no problema a ser solucionado. Deste modo o algoritmo DWNN foi

escolhido realizar a tarefa de aproximação do erro, recebendo como o conjunto de dados as dimensões FÓSFORO SENSOR e POTÁSSIO SENSOR, dados na equação 6:

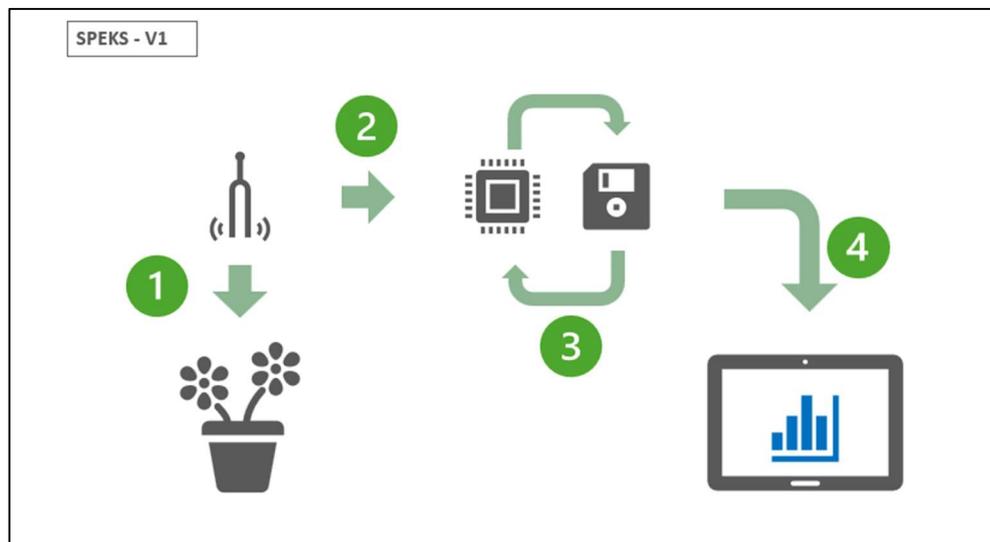
$$X_{sensor} = (P_{Sensor}, K_{Sensor}), \quad (6)$$

sendo  $X_{sensor}$ , pré-processado utilizando o pré-processamento *MinMax*, seção 2.5.1. Os valores de resposta colocamos as dimensões: FÓSFORO LABORATÓRIO e POTÁSSIO LABORATÓRIO, sendo definido na equação 7, como:

$$Y_{lab} = (P_{lab}, K_{lab}) \quad (7)$$

Então o funcionamento do sensor é realizado da seguinte forma: O sensor é colocado no solo e executa a leitura, figura 12 (1), gerando um registro de entradas  $X_{sensor,i}$ , figura 12 (2), utilizando os dados obtidos em  $X_{sensor}$ ,  $Y_{lab}$ , é feito o processamento utilizando o algoritmo DWNN, (3) por último gerando uma leitura bem mais próxima a análise do laboratório, como apresentado na figura 14 (4)

**Figura 14: Exemplo dos processos do protótipo SPEKS.**



Fonte: Elaborada pelo autor.

Na última etapa de desenvolvimento desse projeto, a avaliação da técnica é medida utilizando dois modelos. O 10-Fold-Validation, seção 2.6.1, para atestar a inferência da técnica de regressão utilizando o algoritmo DWNN; e o teste de parametrização no qual geramos uma variação de 0.1 para cada  $\sigma = 0.1$ , até  $\sigma = 1$ , em busca de um erro menor, ambos os testes são apresentados na seção 4.

## 4 RESULTADOS ESPERADOS

Para o comparativo entre os resultados, iniciou-se com os levantamentos a partir as amostras de laboratoriais de 8 amostras distintas representados na tabela 2:

**Tabela 2: Discriminação dos resultados de Fosforo 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.

Posteriormente foram elaboradas as amostras do protótipo SEPKS, com a utilização de dois sensores distintos para as medições, efetuando 6 testes por amostra de solo, no qual Dataset foi construído, seção 3.2, com os respectivos resultados laboratoriais de cada amostra apresentados na tabela 2 na seção Apêndice.

Após o levantamento dos dados foram observadas divergências entre os resultados laboratoriais e os resultados dos sensores. Contudo os dados foram submetidos a análise para obtenção dos valores de erros padrão, através do método de Erro absoluto afim de obtermos a dispersão dos dados.

O MAE (Erro Médio Absoluto) e calculado entre as colunas de variáveis explicadas, dadas por  $Y_{lab}$  (Fósforo Sensor e Fósforo Laboratório) e entre variáveis explicativas, dadas por  $X_{sensor}$  (Potássio Sensor e Potássio Laboratório) demonstrados na tabela 2, empregando a seguinte formula dada pela equação 8:

$$MAE = \frac{\sum_{i=1}^n |X_{sensor,i} - Y_{lab,i}|}{n}, \quad (8)$$

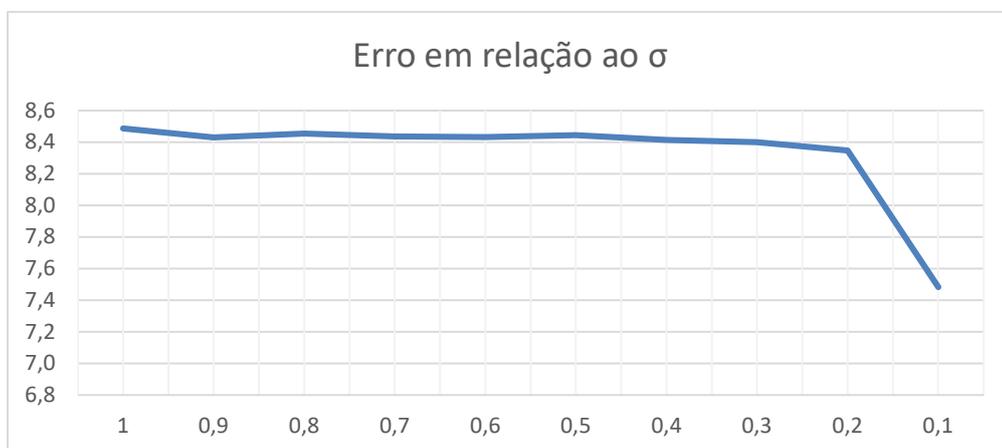
no qual:  $X_{sensor,i}$  é o valor do sensor para a amostra  $i$ ;  $Y_{lab,i}$  é o valor do laboratório para a amostra  $i$ ; e  $n$  é o número total de amostras, neste caso, 96 registros. Desta forma são somados a diferença absoluto entre cada linha de dados, posteriormente é obtido os valores médios da soma dos erros. Obtendo um erro médio de 79,60.

Esses resultados indicam uma divergência de análises significativa entre as leituras obtidas pelo sensor e as analisadas no laboratório. Para que os valores de MAE sejam considerados próximos, eles deveriam estar mais próximos de zero. Isso afirma que pode haver uma discrepância na precisão das medições do sensor em comparação com as análises laboratoriais. Contudo o protótipo foi desenvolvido com o código adquirido do fabricante, com uma leitura crua do sensor, em que muitas variáveis no campo de tensões elétricas podem afetar os resultados. Contudo, o microcontrolador utilizado para geração do protótipo permite embarcar uma solução no código fonte, sendo assim possível a empregabilidade de técnicas de tratativas de erros, por meio de algoritmos de aprendizado de máquinas, neste trabalho foi utilizada o DWNN englobado em aprendizado supervisionado, esse algoritmo é útil em situações em que a proximidade dos pontos de dados é um indicador importante da semelhança.

O DWNN (MITCHELL, 1997) é algoritmo de aprendizado de máquina supervisionado e frequentemente usado para regressão e funciona encontrando os “ $\sigma$ ” exemplos de treinamento mais próximos no espaço de entrada. Sua função coleta os dados de saídas do sensor calculando a distância de uma matriz predefinidos com base nos dados já amostrados, calculando o peso dos vizinhos mais próximos.

Para a validação dos resultados primeiramente foi realizado um teste de parametrização em busca do melhor hiper parâmetro ( $\sigma$ ) para ser embarcado no microcontrolador. Um teste de parametrização variando o  $\sigma = 1$ , até  $\sigma = 0,1$ , foi realizado, para cada teste de  $\sigma$  um teste de *10-Fold-Validation* foi realizado para verificar o erro médio absoluto. Após os testes foi constatado que o  $\sigma = 0,1$  apresentou uma redução do erro em quase 1 ponto, como apresentado no gráfico 1:

**Gráfico 1: Teste de parametrização entre o Erro Médio Absoluto e o hiper parâmetro  $\sigma$ .**



Fonte: Elaborada pelo autor.

O teste apresenta uma queda acentuada quando  $\sigma = 0,1$ , portanto sendo esse o valor escolhido para deixar como padrão no protótipo. O teste de 10-Fold-Validation com o hiperparâmetro  $\sigma = 0,1$ , confirmam o erro médio gerado no teste de parametrização, apresentado na tabela 3.

**Tabela 3: 10-Fold-Validation do Dataset utilizado com  $\sigma = 0,1$ .**

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

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 proposta de criação do protótipo se mostrou bastante desafiadora por vários motivos. Os resultados obtidos por meio das análises de solo utilizando tanto os sensores quanto os testes laboratoriais revelaram uma diferença significativa entre os dados fornecidos pelos sensores e os valores de referência do laboratório. Após a aplicação do método de cálculo do Erro Médio Absoluto (MAE), de 79,60. Estes valores indicam uma discrepância considerável entre as medições dos sensores e as análises laboratoriais, sugerindo uma precisão relativamente baixa dos sensores em comparação com os métodos convencionais de análise de solo.

A da aplicação do algoritmo DWNN como aplicação de aprendizado de máquina trouxe uma grande melhoria na aproximação do erro, minimizando em mais de 10 vezes o erro médio absoluto em relação aos valores reais, com um erro inferior a 10%, indicando que a prática é bastante promissora. Em especial a leitura do macronutriente potássio que já o erro médio desse macronutriente ficou inferior a um (1).

Uma última dificuldade foi em relação a embarcar a solução de aprendizado de máquinas no microcontrolador, por este ter uma capacidade de armazenamento bastante reduzida, mesmo assim utilizando algumas técnicas de otimização foi possível embarcar o algoritmo e o *Dataset* normalizado.

Como trabalho futuro busca-se comparar outros métodos de Aprendizado de Máquinas que sejam possíveis embarcar no microcontrolador afim de aproximar ainda mais o erro apresentado a zero (0).

## REFERÊNCIAS

ANDRADE, K.; FACCIN, K.; PHILERENO, D. C.; RIBAS, F.T.T. **Pesquisa científica** fica a dica. 2. ed. Porto Alegre, 2020.

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.

AGRONÔMICA, E. **O que são macro e micronutrientes para as plantas?** Yara Brasil, 2018. Disponível em: <https://www.yarabrasil.com.br/conteudo-agronomico/blog/macro-e-micronutrientes-plantas/>. Acesso em: 19 mar. 2024.

AGROPRECISION. **Mapeamento-da-fertilidade**. fotografia. Altura: 648. Largura: 365.4. 209Kb. Formato Jpeg. Agronegócio. 2022. Disponível em: <https://www.agroprecision.com.br/wp-content/uploads/2020/05/MAPEAMENTO-DA-FERTILIDADE.jpeg>. Acesso em: 22.Mar.2024.

ALCARDE, J. C.; GOMES, F. P.; MALAVOLTA, E. **Adubos & adubações**. 1. Ed. São Paulo: Nobel, 2008.

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.

BARICHELLO, 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](https://repositorio.ufsm.br/bitstream/handle/1/30906/Barichello_Diana_Luisa_2023_TCC.pdf?sequence=1&isAllowed=y). Acesso em 01 mai. 2024.

BARTH, N. L.; SAMARTINI, A.; SICSÚ, A. L. **Técnicas de machine learning**. 1. ed. São Paulo. Blucher, 2023.

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-de-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.

BLOOM, A.; EPSTEIN, E. **Nutrição mineral de plantas: princípios e perspectivas.** Tradução: Maria Edna Tenório Nunes. 2. Ed. Londrina: Planta, 2006.

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.

DIAMOND, J. Colapso: **Como as sociedades escolhem o fracasso ou o sucesso.** Tradução: Raposo, A. 5. ed. Rio de Janeiro: Record, 2005.

DONAGEMMA, G. K.; FONTANA, A.; TEXEIRA, G. K.; TEXEIRA, P. C. **Manual de métodos de análise de solo.** 3 ed. Brasília: Embrapa, 2017.

DUAIK, G. **Guia inovações tecnológicas na agricultura.** São Paulo: Amazon Digital Services, 2023.

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.

GUIMARÃES, L. M. S.; MEIRELES, M. R. G.; ALMEIDA, P. E. M. Avaliação das etapas de pré-processamento e de treinamento em algoritmos de classificação de textos no contexto da recuperação da informação. **Perspectivas em Ciência da Informação.** 2019, v. 24, n. pp. 169-190. Disponível em: < <https://www.scielo.br/j/pci/a/p55xWvrLwj3zTjbscWdtp4M/#>. Acesso em : 09 jun.2024.

HARARI, Y. N. **Sapiens: História Breve da Humanidade.** ed.1. Tradução de Marcantônio. J. Porto Alegre: L & PM. 2013.

JOÃO ANDRADE, J. C.; CANTARELLA, H.; QUAGGIO, J.A; RAIJ.B.V. **Análise química para avaliação da fertilidade de solos tropicais.** 1. ed. Campinas: Instituto Agronômico, 2001.

JORGE, H. D. **Amostragem do solo para análise química.** ed.1 Porto Velho: Embrapa Uepae, 1986.

LIMA, F. H. S. P. Automação residencial com ESP8266 NodeMCU e Assistente Virtual. 2023. (Trabalho de Conclusão de Curso). Análise e Desenvolvimento de Sistemas. Instituto Federal de Educação, Ciência e Tecnologia de Goiás (IFG). Jataí. 2023 Disponível em: [https://repositorio.ifg.edu.br/bitstream/prefix/1638/1/tcc\\_Fernando%20Henrique%20Silva%20Paula%20Lima.pdf](https://repositorio.ifg.edu.br/bitstream/prefix/1638/1/tcc_Fernando%20Henrique%20Silva%20Paula%20Lima.pdf). Acesso em: 01 jun. 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 web-server 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-web-server>. Acesso em: 15 mai. 2024.

OLIVEIRA, R. R. **Uso do microcontrolador ESP8266 para automação residencial**. (Trabalho de conclusão de curso) – Curso de Engenharia de Controle e Automação da Escola Politécnica, Universidade Federal do Rio de Janeiro: 2017. Tabela. Disponível em: <http://repositorio.poli.ufrj.br/monografias/monopoli10019583.pdf>. Acesso em: 01 jun. 2024.

ORLANDO F, J.; RODELLA, A. A. **Análise química do solo e recomendação de adubação**. Instituto do Açúcar e do Alcool. Piracicaba: Planalsucar, 1983.

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-rural-deixa-de-lucrar-quando-nao-faz-o-exame-da-planta>. Acesso em 15.Mar.2024.

PRADO, H. Enquete - **Amostragem de solo podologia fácil**. 2022. Disponível em: <https://www.pedologiafacil.com.br/enquetes/enq55.php>. Acesso em: 22.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-de-solo-e-por-que-o-nitrogenio-nao-aparece-na-mesma/>. Acesso em: 29.Mar.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-de-futuro/agrodigital/sinal-e-tendencia/avanco-da-ciencia-de-dados-e-big-data-inteligencia->

artificial-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-agricultura-inteligente-usando-iot/>. Acesso em 26.Mar.2024.

SILVA, E. Internet no campo leva operadoras a adequar modelo de negócios. **Globo Rural**. 2022. Disponível em: <https://globorural.globo.com/Noticias/Empresas-e-Negocios/noticia/2022/08/internet-no-campo-leva-operadoras-adequar-modelo-de-negocios.html>> Acesso em 15.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/como-e-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.

VITAS. **absorcao-planta-002**. Altura: 404 pixels. Largura: 1024 pixels. 174.Kb Formato: png. Absorção de Nutrientes. Nutrição. 2024. Disponível em: <https://sqm-vitas.com.br/wp-content/uploads/2020/09/30674A-12-absorcao-planta-002-1024x404.png>. Acesso em 20.Mar.2024.

## APÊNDICE

Tabela 4. Discriminação dos resultados de Fosforo e Potássio dos e sensores e laboratoriais

$X_{sensor}$		$Y_{lab}$	
Fósforo Sensor	Potássio Sensor	Fósforo Laboratório	Potássio laboratório
10	69	27	94
10	69	27	94
10	68	27	94
9	68	27	94
10	69	27	94
10	70	27	94
44	148	27	94
44	148	27	94
45	147	27	94
44	148	27	94
44	145	27	94
46	145	27	94
9	70	19	70
9	70	19	70
9	71	19	70
9	70	19	70
9	70	19	70
9	70	19	70
37	133	19	70
37	135	19	70
37	129	19	70
37	135	19	70
37	133	19	70
36	133	19	70
10	70	5	102
10	70	5	102
10	70	5	102
9	70	5	102
10	71	5	102
10	67	5	102
26	107	5	102
25	107	5	102
26	107	5	102
24	107	5	102
25	107	5	102
25	107	5	102
11	72	29	125
11	70	29	125
11	72	29	125
9	72	29	125
10	71	29	125
11	72	29	125
38	134	29	125

$X_{sensor}$		$Y_{lab}$	
Fósforo Sensor	Potássio Sensor	Fósforo Laboratório	Potássio laboratório
41	133	29	125
38	134	29	125
41	132	29	125
38	134	29	125
38	134	29	125
11	71	14	133
11	70	14	133
11	71	14	133
11	70	14	133
11	71	14	133
11	71	14	133
25	103	14	133
25	103	14	133
23	103	14	133
25	103	14	133
25	117	14	133
25	104	14	133
15	81	15	344
15	79	15	344
15	81	15	344
15	82	15	344
14	81	15	344
14	80	15	344
35	127	15	344
35	128	15	344
35	127	15	344
35	128	15	344
35	127	15	344
34	125	15	344
9	68	5	63
9	68	5	63
9	68	5	63
9	67	5	63
9	68	5	63
9	68	5	63
22	99	5	63
21	99	5	63
22	99	5	63
20	99	5	63
22	100	5	63
22	99	5	63
9	69	10	215
9	69	10	215
10	69	10	215
10	69	10	215
9	69	10	215
9	69	10	215
43	145	10	215
43	145	10	215

---

$X_{sensor}$		$Y_{lab}$	
<b>Fósforo Sensor</b>	<b>Potássio Sensor</b>	<b>Fósforo Laboratório</b>	<b>Potássio laboratório</b>
46	137	10	215
43	145	10	215
44	145	10	215
43	145	10	215

---

Fonte: Elaborado pelo autor.