

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**EVANDRO DA SILVA DOS SANTOS**

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM SUPERVISIONADA DE  
MÁQUINA EM SISTEMAS EMBARCADOS NO AUXÍLIO À APLICAÇÃO DE  
DEFENSIVOS AGRÍCOLAS**

**MEDIANEIRA**

**2023**

**EVANDRO DA SILVA DOS SANTOS**

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM SUPERVISIONADA DE  
MÁQUINA EM SISTEMAS EMBARCADOS NO AUXÍLIO À APLICAÇÃO DE  
DEFENSIVOS AGRÍCOLAS**

**Application of supervised machine learning algorithms in embedded systems  
to assist the application of agricultural pests**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Tecnologias Computacionais Para O Agronegócio da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Tecnologias Computacionais Aplicadas À Produção Agrícola E Agroindústria.

Orientador (a): Prof. Dr. Gilvan Moisés Bertollo.

**MEDIANEIRA**

**2023**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



---

EVANDRO DA SILVA DOS SANTOS

**APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM SUPERVISIONADA DE  
MÁQUINA EM SISTEMAS EMBARCADOS NO AUXÍLIO À APLICAÇÃO DE  
DEFENSIVOS AGRÍCOLAS**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Tecnologias Computacionais Para O Agronegócio da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Tecnologias Computacionais Aplicadas À Produção Agrícola E Agroindústria.

Data de aprovação: 31 de Março de 2023

Dr. Gilvan Moises Bertollo, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Alfran Tellechea Martini, Doutorado – Universidade Federal de Santa Maria (UFSM)

Dra. Fabiana Costa De Araujo Schutz, Doutorado – Universidade Tecnológica Federal do Paraná

Thiago Franca Naves - Universidade Tecnológica Federal do Paraná

Dedico este trabalho à minha família, pelos  
momentos de ausência.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus pela vida, saúde, família, amigos e às oportunidades a mim concedidas, como esta, de avançar no caminho acadêmico.

Agradeço ao Prof. Dr. Gilvan Moisés Bertollo, não só pela orientação do trabalho, mas também pela amizade. Muito obrigado pela confiança no meu trabalho, pelo respeito, por me ensinar, pela compreensão e pelos sábios conselhos acadêmicos e da vida sempre que o procurei para conversar.

Agradeço também a minha mãe Zilda, e minha querida irmã Aparecida, que me apoiaram durante toda a caminhada, entendendo não só minha ausência, mas também, dividindo momentos de alegrias e realizações. Agradeço por todos seus esforços, incentivos e dedicação durante todo o período, sendo sem sombra de dúvidas, partes fundamentais para a conclusão de mais uma etapa.

A todos os professores do ensino básico, fundamental, médio, graduação e pós-graduação, pela contribuição na minha formação pessoal e profissional, que incentivaram e ensinaram muito além dos conteúdos previstos, sendo referências em minha vida profissional.

A Universidade Tecnológica Federal do Paraná e ao Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio pelas oportunidades e excelentes condições de estudo a mim concedidas.

As amizades feitas no curso, pela colaboração na execução das atividades. A todas as pessoas que contribuíram diretamente ou indiretamente, para que eu vencesse mais esta etapa em minha vida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001”.

A todos vocês o meu MUITO OBRIGADO!

Eu tinha um plano, mas Deus tinha um propósito.

## RESUMO

A aprendizagem de máquina tem sido cada vez mais utilizada para aprimorar o monitoramento e previsão das condições meteorológicas. A mesma, utiliza um grande volume de dados para estabelecer padrões e de forma preditiva categorizar os novos dados de entrada. Dessa forma, dados coletados por estações agro meteorológicas automáticas causam impacto significativo na coleta e processamento de dados, pois os mesmos apresentam condições específicas para a execução de determinadas tarefas inerentes ao clima, como por exemplo, a aplicação de defensivos agrícolas, onde pode ocorrer o fenômeno da deriva. O presente trabalho teve como objetivo abordar a possibilidade de aplicação de aprendizagem de máquina e conceitos IoT em estações meteorológicas locais, visando minimizar tal impacto da deriva na produção agrícola. São apresentadas discussões sobre o funcionamento e o desenvolvimento de sistemas de aprendizagem de máquina em seu sistema embarcado, visando melhorar a exatidão e a coleta de informações e utilizando-as como auxílio à aplicação de defensivos agrícolas. Dessa forma, foi desenvolvida uma estação com um sistema embarcado para a coleta dos dados climáticos em tempo real, utilizando modelos de aprendizado de máquina para identificar as condições meteorológicas ideais para a aplicação dos defensivos, sendo a mesma funcionando como repetidor de sinal WI-FI. Também foi desenvolvida uma plataforma de monitoramento para os dados meteorológicos coletados, e apresentação das respectivas respostas dos algoritmos de aprendizagem de máquina como auxílio à pulverização, denominada *i-Cida*. Por fim, apresenta-se as taxas de acertos dos algoritmos em testes de laboratório, na empresa rural parceira e os resultados dos algoritmos no microcontrolador no painel da aplicação desenvolvida, além de comparar os níveis atingidos de IoT pelo projeto.

Palavras-chave: aprendizagem de máquina; deriva; pulverização; agricultura de precisão; inteligência artificial.

## ABSTRACT

Machine learning has been increasingly used to improve weather monitoring and forecasting. It uses a large volume of data to establish patterns and predictively categorize new input data. Thus, data collected by automatic agro-meteorological stations have a significant impact on the collection and processing of data, as they present specific conditions for the execution of certain tasks inherent to the climate, such as, for example, the application of agricultural defensives, where the drift phenomenon. The present work aimed to address the possibility of applying machine learning and IoT concepts in local meteorological stations, aiming to minimize the impact of drift on agricultural production. Discussions are presented on the operation and development of machine learning systems in its embedded system, aiming to improve the accuracy and collection of information and using them as an aid to the application of agricultural pesticides. In this way, a station was developed with an embedded system for the collection of climatic data in real time, using machine learning models to identify the ideal meteorological conditions for the application of pesticides, which works as a WI-FI signal repeater. . A monitoring platform was also developed for the collected meteorological data, and the presentation of the respective answers of the machine learning algorithms as an aid to the spraying, called i-Cida. Finally, the success rates of the algorithms in laboratory tests, in the rural partner company and the results of the algorithms in the microcontroller in the panel of the developed application are presented, in addition to comparing the achieved levels of IoT by the project.

Keywords: machine learning; drift; pulverization; precision agriculture; artificial intelligence.



## LISTA DE ILUSTRAÇÕES

Figura 1 - Aplicações para IoT .....	40
Figura 2 - Diagrama básico de um sistema embarcado.....	41
Figura 3 - A hierarquia de aprendizado de máquina .....	46
Figura 4 - Fluxo para o aprendizado de máquina em modelagem preditiva .....	48
Figura 5 - Sistema gerenciador de banco de dados .....	55
Figura 6 - Fluxo de funcionamento básico da estação .....	62
Figura 7 - Exemplo de dados faltantes .....	70
Figura 8 - Divisão do conjunto de dados para Machine learning .....	74
Figura 9 - Os quatro níveis IoT.....	97
Fotografia 1 - Torre de distribuição de internet .....	59
Fotografia 2 - Pluviômetro automático de balança .....	65
Fotografia 3 - Anemômetro e anemoscópio .....	66
Fotografia 4 - Estação meteorológica desenvolvida .....	86
Imagem 1 - Município de implantação do projeto.....	58
Imagem 2 - Equipamentos utilizados para o WI-FI local.....	60
Imagem 3 - Área de abrangência do WI-FI.....	61
Imagem 4 - Black Board Mega 2560 R3 e Shield Ethernet W5500.....	63
Imagem 5 - Sensor BME 280 e abrigo .....	63
Imagem 6 - Sensor de umidade do solo S12.....	64
Imagem 7 - Separação dos dados preditivos.....	71
Imagem 8 - Exemplo de dados aleatórios para pulverização, "SIM" .....	72
Imagem 9 - Exemplo de dados aleatórios para a não pulverização, "NÃO" .....	72
Imagem 10 – Bibliotecas para arduino .....	80
Imagem 11 – Inclusão das bibliotecas de aprendizagem de máquina .....	80
Imagem 12 – Colunas do banco de dados.....	83
Imagem 13 – Dados brutos sendo colocados ao banco de dados .....	83
Imagem 14 – Painel de controle – Dashboard .....	87
Imagem 15 – Painel de aprendizagem de máquina .....	88
Imagem 16 – Painel satélite .....	88
Imagem 17 – Dados globais.....	89
Imagem 18 – Painel de localização .....	90
Imagem 19 – Painel de monitoramento .....	91
Imagem 20 – Painel sobre .....	91
Quadro 1 - Expressão utilizada para separar os dados preditivos.....	71
Quadro 2 - Bibliotecas para aprendizagem de máquina .....	74
Quadro 3 – Código de conjunto de dados .....	76
Quadro 4 - Executa treinamento de máquina .....	76
Quadro 5 – Código para salvar treinamento em linguagem C .....	79
Quadro 6 – Exemplo de arquivo de cabeçalho Random Forest Classifier .....	79
Quadro 7 – Respostas do treinamento de máquina.....	80
Quadro 8 – Código PHP para consultas ao banco de dados .....	84

## LISTA DE TABELAS

<b>Tabela 1 – Resultados das métricas de avaliação.....</b>	<b>92</b>
<b>Tabela 2 – Dados climáticos da coleta .....</b>	<b>93</b>
<b>Tabela 3 – Taxa de acertos no laboratório.....</b>	<b>93</b>
<b>Tabela 4 - Taxa de acertos na propriedade .....</b>	<b>94</b>
<b>Tabela 5 - Taxas de acerto total .....</b>	<b>95</b>

## LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizagem de Máquina
ANDEF	Associação Nacional de Defesa Vegetal
INMET	Instituto Nacional de Meteorologia
CSV	Valores separados por Vírgula
I.A	Inteligência Artificial
IoT	Internet das Coisas
ML	Machine Learning
NaN	Not a Number
TDMA	Time Division Multiple Access

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>25</b>
<b>1.1</b>	<b>Objetivos</b> .....	<b>27</b>
1.1.1	Objetivo geral .....	27
1.1.2	Objetivos específicos .....	27
<b>1.2</b>	<b>Justificativa</b> .....	<b>28</b>
<b>1.3</b>	<b>Organização do trabalho</b> .....	<b>30</b>
<b>2</b>	<b>REVISÃO DA LITERATURA</b> .....	<b>31</b>
<b>2.1</b>	<b>Histórico da pulverização agrícola</b> .....	<b>31</b>
<b>2.2</b>	<b>Tecnologia de pulverização agrícola</b> .....	<b>32</b>
<b>2.3</b>	<b>Deriva na aplicação de defensivos</b> .....	<b>35</b>
<b>2.3</b>	<b>Agrometeorologia</b> .....	<b>36</b>
<b>2.4</b>	<b>Estações meteorológicas</b> .....	<b>37</b>
<b>2.5</b>	<b>Redes WI-FI</b> .....	<b>38</b>
<b>2.6</b>	<b>Soluções IoT</b> .....	<b>38</b>
<b>2.7</b>	<b>Sistemas embarcados</b> .....	<b>40</b>
2.7.1	Hardware embarcado .....	42
2.7.2	Software embarcado .....	43
<b>2.8</b>	<b>Inteligência artificial</b> .....	<b>44</b>
2.8.1	Aprendizagem de máquina.....	45
2.8.2	Aprendizagem supervisionada .....	46
2.8.3	Análise preditiva .....	47
<b>2.9</b>	<b>Algoritmos de aprendizagem de máquina</b> .....	<b>49</b>
2.9.1	DecisionTreeClassifier .....	49
2.9.2	DecisionTreeRegressor .....	49
2.9.3	Extra TreeClassifier.....	50
2.9.4	GaussianNaiveBayes (NB).....	50
2.9.5	Análise discriminante linear .....	51
2.9.6	Regressão linear .....	51
2.9.7	Regressão logística .....	52
2.9.8	Support Vector Machines (One Class SVM).....	52
2.9.9	Random Forest Classifier .....	52
2.9.10	Random Forest Regressor .....	53
2.9.11	Support Vector Classifier .....	53

<b>2.10</b>	<b>Banco de dados</b> .....	<b>54</b>
<b>2.11</b>	<b>Aplicações Web</b> .....	<b>56</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>58</b>
<b>3.1</b>	<b>Descrição da localidade</b> .....	<b>58</b>
<b>3.2</b>	<b>Implantação da rede wireless</b> .....	<b>58</b>
<b>3.3</b>	<b>Desenvolvimento da estação meteorológica</b> .....	<b>61</b>
3.3.1	Sensores utilizados .....	63
3.3.2	Sensor BME280 .....	63
3.3.3	Sensor de umidade do solo .....	64
3.3.4	Pluviômetro automático de báscula .....	65
3.3.5	Anemômetro de concha e Anemoscópio .....	65
3.3.6	Cálculos efetuados pela estação.....	66
<u>3.3.6.1</u>	<u>Ponto de orvalho</u> .....	<u>67</u>
<u>3.3.6.2</u>	<u>Altura da base das nuvens</u> .....	<u>67</u>
<u>3.3.6.3</u>	<u>Sensação térmica</u> .....	<u>68</u>
<b>3.4</b>	<b>Pré-processamento</b> .....	<b>68</b>
3.4.1	Levantamento dos dados históricos.....	68
3.4.2	Exclusão dos dados incompletos .....	69
3.4.3	Base de dados – <i>Dataset</i> .....	70
<b>3.5</b>	<b>Processamento</b> .....	<b>73</b>
3.5.1	Ferramentas utilizadas para o treinamento de máquina .....	73
3.5.2	Treinamento dos modelos .....	73
3.5.3	Métricas de avaliação .....	77
<b>3.6</b>	<b>Pós-processamento</b> .....	<b>78</b>
3.6.1	Algoritmos no microcontrolador .....	78
<b>3.7</b>	<b>Desenvolvimento da aplicação web</b> .....	<b>81</b>
3.7.1	Manipulação do banco de dados.....	81
<u>3.7.1.1</u>	<u>Ferramenta MySql</u> .....	<u>82</u>
3.7.2	Conexão do sistema com o banco de dados .....	84
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>86</b>
<b>4.1</b>	<b>Montagem da estação</b> .....	<b>86</b>
<b>4.2</b>	<b>Aplicação web</b> .....	<b>87</b>
4.2.1	Dashboard .....	87
4.2.2	Painel aprendizagem de máquina .....	87
4.2.3	Painel satélite .....	88

4.2.4	Painel dados globais.....	89
4.2.5	Painel localização .....	89
4.2.6	Painel monitoramento.....	90
4.2.7	Painel sobre .....	91
<b>4.3</b>	<b>Resultados das métricas de avaliação .....</b>	<b>92</b>
<b>4.4</b>	<b>Taxas de acertos.....</b>	<b>92</b>
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>99</b>
<b>5.1</b>	<b>Sugestões de trabalhos futuros.....</b>	<b>99</b>
	<b>REFERÊNCIAS .....</b>	<b>101</b>
	<b>APÊNDICE A - Torre de distribuição WI-FI I.....</b>	<b>111</b>
	<b>APÊNDICE B - Torre de distribuição WI-FI II.....</b>	<b>113</b>
	<b>APÊNDICE C - Estação metereologica I.....</b>	<b>115</b>
	<b>APÊNDICE D - Estação metereologica II.....</b>	<b>117</b>
	<b>APÊNDICE E - Estação metereologica III.....</b>	<b>119</b>
	<b>APÊNDICE F - Estação metereologica IV.....</b>	<b>121</b>
	<b>APÊNDICE G - Página inicial .....</b>	<b>123</b>
	<b>APÊNDICE H - Painel de controle .....</b>	<b>125</b>
	<b>APÊNDICE I - Tela aprendizagem de máquina.....</b>	<b>127</b>
	<b>APÊNDICE J - Exemplo de monitoramento .....</b>	<b>129</b>
	<b>APÊNDICE K - Tela sobre .....</b>	<b>131</b>
	<b>ANEXO A - Tela satélite .....</b>	<b>133</b>
	<b>ANEXO B - Dados globais (GFS 2m Temperature °C).....</b>	<b>135</b>
	<b>ANEXO C - Dados globais (GFS Precipitation (mm/h), Clouds).....</b>	<b>137</b>
	<b>ANEXO D - Dados globais (GFS 10m Wind Speed(kt)).....</b>	<b>139</b>
	<b>ANEXO E - Globais (Last Glacial Maximum) .....</b>	<b>141</b>
	<b>ANEXO F - Dados globais (16% Modern, 84% LGM) .....</b>	<b>143</b>
	<b>ANEXO G - Dados globais (33% Modern, 67% LGM) .....</b>	<b>145</b>
	<b>ANEXO H - Dados globais (50% Modern, 50% LGM) .....</b>	<b>147</b>
	<b>ANEXO I - Dados globais (66% Modern, 34% LGM) .....</b>	<b>149</b>
	<b>ANEXO J - Dados globais (83% Modern, 17% LGM) .....</b>	<b>151</b>
	<b>ANEXO K - Dados globais (Little Ice Age, ca. 1850).....</b>	<b>153</b>
	<b>ANEXO L - Dados globais (ModernClimate, 1979-2000).....</b>	<b>155</b>
	<b>ANEXO M - Dados globais (IPCC RCP-8.5 2025).....</b>	<b>157</b>
	<b>ANEXO N - Dados globais (IPCC RCP-8.5 2050).....</b>	<b>159</b>
	<b>ANEXO O - Dados globais (IPCC RCP-8.5 2075).....</b>	<b>161</b>
	<b>ANEXO P - Dados globais (IPCC RCP-8.5 2100).....</b>	<b>163</b>
	<b>ANEXO Q - Tela localização .....</b>	<b>165</b>

## 1 INTRODUÇÃO

Conceitualmente, a inteligência artificial é a capacidade de sistemas computacionais realizarem tarefas que normalmente são executadas por seres humanos, como tomar decisões, raciocinar, aprender e perceber o ambiente. É usada para solucionar problemas com alto grau de complexidade ou realizar tarefas de forma mais eficiente. Tendo por objetivo criar rotinas computacionais capazes de operar com autonomia e raciocínio próprio (CARVALHO et al., 2021).

A inteligência artificial é um campo de estudo amplamente explorado nos últimos anos e possui aplicações em diversos setores. Suas possibilidades são enormes e ao utilizá-la, é possível aumentar a produtividade, melhorar a tomada de decisão, prever o comportamento do usuário, melhorar a sua experiência e, como proposto, utilizá-lo como auxílio à pulverização agrícola.

Nesse contexto surge a aprendizagem de máquina, ramo que se concentra na capacidade dos computadores em aprender com as experiências e melhorar seu desempenho ao longo do tempo. É um campo de estudo focado em criar algoritmos capazes de extrair conhecimento de dados. Esses algoritmos são projetados, e após treinados, tornarem-se independentes de instruções humanas explícitas. A aprendizagem de máquina tem sido utilizada para tarefas como reconhecimento de imagens, processamento de linguagem natural, detecção de fraudes e até mesmo previsão do tempo.

De acordo com um estudo realizado em 2019 pela *Market Sand Markets*, empresa especializada em pesquisa de mercado, o uso de inteligência artificial na agricultura deve aumentar cerca de 25,5 % até o ano de 2026, impulsionado pela crescente implementação de geração de dados por meio de sensores e imagens aéreas, aumentando a produtividade por meio da tecnologia de aprendizado de máquina, visão computacional e análise preditiva.

Concomitantemente, a deriva é um fator, que por vezes, pode estar presente nas aplicações de defensivos agrícolas, pois se trata da deslocação do defensivo agrícola aplicado para além da área destinada. Ocorre principalmente em locais com ventos fortes, pois o produto é carregado pelo ar e acaba atingindo outras áreas que não foram destinadas à sua aplicação.

A deriva pode ser evitada com medidas práticas de controle, como a utilização de equipamentos específicos para limitar o alcance dos defensivos agrícolas; velocidades de pulverização adequadas; barreiras físicas; e calibrações dos equipamentos corretamente. Além disso, é importante monitorar as condições climáticas antes da aplicação dos produtos para evitar que a mesma ocorra.

Desse modo, o presente trabalho visa o desenvolvimento de um sistema embarcado com aprendizagem de máquina, em uma estação meteorológica, cuja finalidade é auxiliar o produtor rural na tomada de decisão quanto ao melhor momento para efetuar aplicação de defensivos agrícolas, uma vez que essa tarefa necessita atentar às condições climáticas para sua execução. Os dados podem ser visualizados através de uma plataforma disponibilizada na internet, portanto, o operador da máquina terá acesso a informações meteorológicas em tempo real podendo tomar decisões mais assertivas sobre o melhor momento para a execução do procedimento fitossanitário.



## **1.1 Objetivos**

### **1.1.1 Objetivo geral**

O desenvolvimento de uma estação meteorológica automática e utilizar seus dados coletados em tempo real para, por meio de algoritmos de aprendizagem máquina executados em um sistema embarcado, reconhecer e mostrar as condições climáticas ideais para aplicação de defensivos agrícolas.

### **1.1.2 Objetivos específicos**

- a) Desenvolver uma estação meteorológica para coletar os dados relativos às condições climáticas atmosféricas e de solo em tempo real.
- b) Utilizar os dados em modelos computacionais de aprendizagem de máquina supervisionado para determinar os momentos favoráveis e não favoráveis à aplicação de defensivos agrícolas.
- c) Desenvolver uma aplicação capaz de mostrar os dados coletados e processados em tempo real ao usuário.

## 1.2 Justificativa

O aumento da produtividade agrícola é um dos fatores que garantem a competitividade do setor. Diversas tecnologias são utilizadas com o objetivo de garantir o desenvolvimento da planta, como o uso de defensivos agrícolas para controlar problemas fitossanitários (SANTIAGO; GUAZZELLI, 2021).

Desse modo, a necessidade de tecnologias mais exatas para a pulverização agrícola e com maior eficiência, é evidenciada pelo aumento constante dos custos na produção rural, bem como a crescente preocupação com a contaminação ambiental. Com isso, são necessários procedimentos e equipamentos adequados para economia de insumos, para a proteção do trabalhador e do meio ambiente (CONTIERO; BIFFE; CATAPAN, 2018).

É importante ressaltar que, os defensivos agrícolas também são conhecidos como, agentes “indispensáveis à viabilidade da maioria dos sistemas produtivos rurais atuais, uma vez que muitos desses sistemas só se sustentariam devido à utilização para compensar sua perda de produtividade” (VEIGA, 2007). Ainda para o mesmo autor, o “benefício mais comum associado à utilização de agrotóxicos seria o aumento na produtividade da lavoura, ou seja, uma maior produção agrícola colhida para uma determinada área plantada”.

Entretanto, durante a aplicação, parte do produto pode ser perdido no ambiente, principalmente por deriva, fenômeno esse que envolve a movimentação física “das gotículas de defensivos agrícolas, que são transportadas pelo ar para outros locais não sendo o alvo de aplicação, principalmente em casos de condições ambientais adversas” (ZHANG et al., 2018). Esse tipo de perda externas pode ocasionar prejuízos causados a outras culturas, e resultar na contaminação ambiental caso as recomendações técnicas não sejam observadas durante a atividade de pulverização (ANDEF, 2004).

Para a ANDEF (2004) o controle da deriva é dever de todo agricultor, visto que, além de representar uma fonte considerável de prejuízos, é a responsável pela contaminação de si mesmo e do ambiente. Portanto, para se fazer um controle efetivo da aplicação, é necessário conhecer pelo menos alguns dos princípios básicos da mesma.

A alta temperatura, velocidade do vento, a baixa umidade relativa dos são consideradas condições meteorológicas adversas que podem favorecer a ocorrência de deriva durante e após as aplicações de defensivos agrícolas sendo as condições ideais para uma aplicação são: umidade relativa do ar mínima de 55%; velocidade do vento de 3 a 10 km/h; temperatura abaixo de 30°C (ANDEF, 2004). Dessa forma, é fundamental o monitoramento dessas condições ambientais para evitar a realização da atividade o procedimento em condições de risco elevadas (HAAS et al., 2022).

Além do dano resultante da perda de agrotóxico e dos prejuízos que podem ser ocasionados em culturas adjacentes, a deriva assume grande importância devido à conscientização da população em relação à qualidade de água e alimentos e a outras questões ambientais (LUNKES, 2019), onde o fenômeno pode resultar em impactos à saúde humana (CUNHA, 2008).

Algumas tecnologias têm sido pesquisadas e incorporadas às pulverizações agrícolas, visando auxiliar a aplicação adequada do produto (GITIRANA et al., 2016; FRANÇA et al., 2017). O principal objetivo é permitir um bom controle, reduzir danos, evitar efeitos negativos ao meio ambiente e garantir a sustentabilidade do sistema (CONTIERO; BIFFE; CATAPAN, 2018).

Dessa forma, “a eficiência na aplicação de agrotóxicos é resultante de uma série de fatores, como seleção dos equipamentos, da calibração, das ferramentas e mecanismos que são capazes de reduzir as perdas por deriva, evaporação e escoamento” (PRECIPITO et al., 2018).

Inúmeros são os fatores não controláveis nesse processo, por outro lado, vários são aqueles passíveis de serem adequados, para que as perdas se situem dentro de um limite aceitável, principalmente não interferindo na eficiência dos produtos utilizados. Pesquisas relacionadas à eficiência da aplicação são essenciais, pois há diversos tipos de pulverizadores, produtos e formulações disponíveis no mercado (MARTINI et al., 2017). Dessa forma, o ajustamento da tecnologia de aplicação às condições climáticas da troposfera local favorece a eficiência da aplicação.

### **1.3 Organização do trabalho**

A estrutura deste trabalho está organizada da seguinte forma. O capítulo 2 apresenta a revisão da literatura, mostrando todos os conhecimentos necessários para o entendimento básico da pesquisa proposta. O capítulo 3 apresenta os materiais e métodos necessários para o desenvolvimento da pesquisa. Já o capítulo 4 apresenta os resultados e discussões, proporcionando uma análise dos resultados obtidos ao decorrer da pesquisa. Por fim, o capítulo 5 apresenta a conclusão do trabalho e as sugestões para os trabalhos futuros.

## 2 REVISÃO DA LITERATURA

### 2.1 Histórico da pulverização agrícola

Em um resumo histórico sobre o aparecimento dos defensivos agrícolas Bohmont (1981) diz que, “os romanos antigos já usavam a fumaça proveniente da queima de enxofre para controlar pulgões que atacavam as plantações de trigo e também usavam sal para controlar ervas daninha”. Já nos primórdios do século XIX, os chineses utilizavam arsênico misturado em água para controlar insetos.

Descobriu-se, no início desse século, que produtos derivados de plantas como a rotenona e a piretrina controlavam diferentes tipos de insetos (CHAIM, 1999). Dessa forma, Akesson & Yates (1979) dividem o desenvolvimento do controle de pragas em três períodos. O primeiro refere-se à época anterior a 1867 em que se utilizavam produtos odoríferos ou irritantes, tais como excrementos e cinzas, mas também se começava a utilizar enxofre, rotenona, piretro, nicotina, óleos animais ou de petróleo.

O segundo, compreendido entre 1867 a 1939, corresponde ao período da descoberta e refinamento da mistura Bordeaux, bem como de outras formulações cúpricas. Exatamente durante esse período, começou o desenvolvimento mais significativo nos equipamentos de aplicação desses produtos. O terceiro período inicia-se a partir de 1939, com a era dos organossintéticos (CHAIM, 1999).

O grande avanço no desenvolvimento dos equipamentos de pulverização surgiu mais precisamente no segundo período. Isso ocorreu em parte devido ao interesse dos agricultores em controlar as produções e melhorar a qualidade dos produtos, e também das consequências da revolução industrial, a qual promoveu o êxodo rural e uma maior concentração de pessoas nas áreas urbanas, aumentando a demanda de produtos agrícolas, mas diminuindo a disponibilidade de mão de obra para trabalhar no campo (CHAIM, 1999).

Posteriormente com o advento da Agricultura 2.0 que incluía as máquinas e a ciência em seus processos, por volta da década de 50, e com a Agricultura 3.0 entre os anos de 1990 e 2010, começou a introduzir-se no mercado os conceitos de

automação e sustentabilidade, os quais fizeram com que a maneira de aplicação dos defensivos mudasse consideravelmente nesse período.

Já a nova era digital com a Agricultura 4.0, em meados de 2010, possibilitou maior conectividade e opções de tecnologias disponíveis nas máquinas agrícolas. Para Spanaki et al. (2021) a agricultura 4.0 está evoluindo rapidamente e se expandindo em vários campos, oferecendo múltiplas oportunidades para agricultores e consumidores.

Os produtores rurais estão aderindo cada vez mais as tecnologias, o que ocasiona uma maior capacidade, planejamento e agilidade na tomada de decisão, da produtividade, tanto na agricultura quanto na pecuária, ambas sob a interferência e conexão de softwares e sistemas digitais às máquinas agrícolas (FACHIN, 2021).

Dessa forma, diversos avanços tecnológicos visando eficiência nas aplicações de defensivos agrícolas vêm sendo desenvolvidos. Tais avanços têm como principal objetivo adicionar a quantidade recomendada de ingrediente ativo no alvo, da maneira mais eficiente e econômica possível (CAMPAGNOLO, 2020), minimizando a perdas dos produtos.

Alguns dos avanços mais comuns incluem a automação de aplicação de defensivos agrícolas (SABARÁ; SANTOS, 2021), com máquinas especialmente projetadas para aplicar defensivos agrícolas de maneira segura e eficiente; o uso de drones, que geralmente são equipados com sensores e câmeras para monitorar o uso de pesticidas e inseticidas em áreas grandes e de difícil acesso (CARVALHO et al., 2019); e o uso de sistemas de informação geográfica (BOLFE; MATIAS; FERREIRA, 2008), que permitem a análise de dados para planejar aplicações de defensivos agrícolas mais eficientes.

Com estas tecnologias, os agricultores podem realizar a aplicação de defensivos agrícolas de maneira mais assertiva, evitando a aplicação excessiva, reduzindo os custos e ajudando a preservar a saúde do meio ambiente e minimizar os impactos financeiros.

## **2.2 Tecnologia de pulverização agrícola**

Tecnologia é a aplicação do conhecimento científico e tecnológico a um determinado processo de produção. Portanto, a tecnologia de aplicação de defensivos

agrícolas é o emprego de conhecimentos para promover a correta colocação do produto biologicamente ativo no alvo, no momento e na quantidade necessária, de forma econômica e com o mínimo de contaminação ambiental (MATUO, 1990).

A eficiência do método de aplicação, seja no controle de pragas e doenças, é aplicar o produto no alvo para obter o efeito desejado, a fim de cobrir o alvo com a máxima eficiência e o mínimo esforço. A tecnologia de aplicação não se resume ao ato de aplicar o produto, mas sim na interação entre vários fatores (cultura, praga, doença, planta invasora, produto, equipamento e ambiente) buscando um controle eficiente, com custo baixo e mínima contaminação ambiental (VARGAS; GLEBER, 2005).

É essencial entender os fatores que influenciam diretamente a forma como os defensivos agrícolas são aplicados e como eles interagem com o ambiente. Para Contiero, Biffe e Catapan (2018), os seguintes fatores se destacam como alguns dos principais:

#### **a. Clima**

Além de ser um fator que restringe o desenvolvimento da cultura, o clima afeta diretamente o controle de doenças, pragas e plantas invasoras, pois determina as condições ambientais existentes. Alguns dos fatores climáticos a serem levados em consideração incluem pluviosidade, temperatura, umidade relativa do ar e ocorrência de ventos, que serão citadas posteriormente.

#### **b. Ingrediente ativo**

É o produto que efetivamente controlará o patógeno. Normalmente, os princípios ativos são testados pelos fabricantes e por meio de instituições oficiais. Ambos podem fornecer informações sobre defensivo a ser usado para controlar o patógeno, a dosagem e a técnica de aplicação que devem ser usadas.

#### **c. Ingrediente inerte**

É com o qual o princípio ativo é misturado para aplicação. Os veículos podem ser líquidos, como água, óleo, etc., ou sólidos, como talco, gesso, argila, etc.,

utilizados como pastas ou grãos. De forma geral, pode-se dizer que uma aplicação defensiva deve tentar utilizar a menor quantidade possível de veículo, pois mesmo um veículo inerte tem custos associados a transporte, diluição, aplicação, etc.

#### **d. Operador**

Por uma variedade de razões, é um dos fatores a ser levado em consideração na aplicação de defensivos agrícolas. Portanto, “a principal delas é que o próprio ser humano é o elo final da cadeia de produção e utilização de alimentos e fibras. Dessa forma, toda e qualquer agressão desnecessária ao meio ambiente, como a aplicação incorreta de defensivos agrícolas, irá refletir no bem-estar do próprio ser humano” (CONTIERO; BIFFE; CATAPAN, 2018).

#### **e. Máquina**

Também é um fator importante, uma vez que é através dela que se faz a aplicação mecanizada dos defensivos (CONTIERO; BIFFE; CATAPAN, 2018). A regulagem, calibração, manutenção e características operacionais da máquina utilizada determinarão o sucesso do tratamento, o qual será determinado pelo nível de controle do patógeno.

Na agricultura de precisão, o aprendizado de máquina tem sido utilizado de muitas maneiras. Dados coletados durante a colheita, plantio e fertilização, por exemplo, podem ser analisados com o propósito de obter vantagem competitiva e, conseqüentemente, vantagem econômica. No trabalho de Russ et al. (2009), por exemplo, redes neurais conhecidas como mapas auto organizáveis (KOHONEN, 1990) foram utilizadas para visualização de dados agrícolas.

As redes neurais foram capazes de identificar e classificar padrões estatísticos nos dados. Isso permitiu a criação de um modelo preditivo para prever o desempenho de uma cultura em condições climáticas específicas. Essa abordagem foi considerada útil para a tomada de decisões relacionadas à agricultura, pois fornece uma maneira de avaliar os riscos associados a determinadas condições climáticas.



### 2.3 Deriva na aplicação de defensivos

Deriva é o desvio do curso pretendido das partículas liberadas no processo de pulverização, o que faz com que desviem do seu alvo e, conseqüentemente, torne-se uma fonte de perdas do produto. Pode ser dividida em endoderiva, que ocorre dentro da cultura, e exoderiva, que ocorre fora da área tratada (CONTIERO; BIFFE; CATAPAN, 2018).

Em alguns casos, também pode ser causada pela aplicação incorreta do produto, como a não observação de distâncias mínimas entre aplicação e alvo, a não utilização de equipamentos adequados ou a aplicação inadequada dos produtos ou em condições climáticas fora das recomendações técnicas.

Além de gerar um desperdício do produto, a deriva pode causar prejuízos econômicos e ainda acentua a crescente preocupação em virtude de seu potencial de risco ambiental (BARCELLOS; CARVALHO; SILVA, 1998). Muitas vezes, o ingrediente ativo se perde devido às condições do ambiente e horários de aplicação inadequados.

De acordo com Sabik et al. (2000), dependendo das condições climáticas no momento da aplicação, apenas uma pequena porcentagem desses produtos realmente atingirá o alvo sendo o restante considerado como um xenobiótico com alto potencial de movimentação para outros lugares, onde se alojam em plantas, solos ou ambientes aquáticos, dando origem a acumulações em determinados ecossistemas.

A temperatura alta e a umidade relativa do ar baixa têm importante efeito sobre a pulverização de produtos fitossanitários, causando evaporação mais rápida das gotas (MATUO, 1990). Como dito anteriormente, segundo a ANDEF (2004), as condições ideais para uma aplicação concentram-se na umidade relativa do ar não inferior a 55%; velocidade do vento de 3 a 10 km/h; temperatura abaixo de 30°C.

Quando a temperatura está alta e a umidade relativa do ar está baixa, a evaporação das gotas de produto é acelerada, podendo causar problemas na eficácia da aplicação, como a redução da concentração do produto aplicado e a dispersão das gotas para fora da área alvo.

Estas condições são importantes para o controle de pragas e doenças que afetam as plantas, pois as gotas de produto que caem sobre elas são mais eficazes.

Por isso, é importante que os produtores rurais e os responsáveis técnicos monitorem as condições climáticas e assim evitar perdas monetárias e de eficiência na aplicação.

### **2.3 Agrometeorologia**

A agrometeorologia, também conhecida como meteorologia agrícola, é o estudo das condições atmosféricas e seus efeitos nos ambientes rurais. Sua principal utilização é nos processos de planejamento e tomada de decisão das propriedades agrícolas, sejam elas destinadas à produção de carne ou vegetais, sendo uma ferramenta fundamental no processo de produção rural (SOUZA, 2012).

A atividade econômica que mais depende das condições climáticas é a agricultura e, em seus sistemas ecológicos, as condições meteorológicas constituem fatores exógenos que afetam diretamente o crescimento, o desenvolvimento e a produtividade de plantas e animais (MONTEIRO, 2009).

Além de interferir nos processos metabólicos das plantas, os fatores meteorológicos também estão diretamente relacionados à produção em diversas atividades rurais. Em torno de 80% da variabilidade da produção agrícola no mundo devem-se às condições meteorológicas durante o ciclo de cultivo (MONTEIRO; SENTELHAS, 2009).

No crescimento, desenvolvimento e produtividade das culturas o clima também afeta a forma como as plantas interagem com microrganismos, pragas, fungos e bactérias, promovendo ou desestimulando o aparecimento de doenças e enfermidades e exigindo a implementação de medidas de controle eficazes. Inúmeras práticas agrícolas, incluindo preparo do solo, plantio, adubação, irrigação, pulverização, colheita, entre outras, dependem de condições específicas de clima e umidade do solo para serem realizadas de forma eficaz (PEREIRA et al., 2002).

Conseqüentemente, o uso de informações meteorológicas e climáticas é essencial para que a agricultura se torne uma atividade sustentável dada a importância do clima para a produção agrícola (SIVAKUMAR et al., 2000). Nesse ambiente, a agrometeorologia, ciência interdisciplinar que estuda o impacto do tempo e do clima na produção de alimentos, fibras e energia, desempenha um papel estratégico na compreensão e solução dos problemas enfrentados pela agricultura (MAVI; TUPPER, 2004).

## 2.4 Estações meteorológicas

São equipamentos utilizados para adquirir dados meteorológicos (termômetro/temperatura do ar, pressão atmosférica/barômetro, higrômetro/umidade relativa do ar, etc.) (INMET, 2019). Essas estações podem ser manuais, usando equipamentos mecânicos e exigindo que profissionais observem e registrem os dados, ou automáticas, usando equipamentos eletrônicos que podem ser programados para monitorar e registrar dados em intervalos predeterminados.

Uma estação meteorológica pode indicar mudanças bruscas de temperatura, verificar indicadores de volume de chuva e radiação solar e identificar a velocidade e a direção do vento. As estações meteorológicas convencionais consistem em sensores que medem variáveis atmosféricas como pressão, temperatura, umidade, precipitação, radiação solar, direção e velocidade do vento. Alguns desses instrumentos são colocados ao ar livre, como pluviômetro, pluviógrafo, actinógrafo e heliógrafo, enquanto outros estão localizados em um local específico, como o psicrômetro, medidores de temperatura máxima e mínima e o termógrafo (KNIPPELBERG; JUNIOR, 2019).

As estações automáticas incluem todos os processos automatizados de coleta de dados. A coleta e o registro de dados são processos eletrônicos, portanto não é necessária nenhuma pessoa para anotações diárias (KNIPPELBERG; JUNIOR, 2019). As configurações automáticas incluem sensores de parâmetros meteorológicos como pressão, temperatura e umidade relativa, precipitação, radiação solar, direção e velocidade do vento que são conectados a uma unidade central de memória.

Como resultado, as configurações automáticas são mais populares devido à sua praticidade, pois estas estações meteorológicas analisam os dados e as informações para criar relatórios precisos e detalhados de estado do tempo, informações essas extremamente importantes para previsões meteorológicas precisas.

## 2.5 Redes WI-FI

Uma rede sem fio é definida como a transmissão de dados sem a necessidade de fios, tornando-se uma opção adequada em situações de mobilidade, necessidade de uso por curtos períodos de tempo, flexibilidade de expansão e necessidade de superar desafios relacionados à instalação (LIMA, 2019). Existe um conceito equivocado quanto ao termo Wi-Fi que é um acrônimo de *Wireless Fidelity*, porém Wi-Fi é simplesmente uma marca de mercado usada para se referir a tecnologia 802.11 WLAN (MATSUNAGA, 2012).

O padrão sem fio IEEE 802.11 é amplamente utilizado para fornecer acesso a redes sem fio locais (WLAN), tanto para conexões temporárias em pontos de acesso (*hotspots*) em cafés, aeroportos, hotéis, bem como em escritórios e empresas (GRACIANO, 2015). Para Olenewae Ciampa(2007), a comunicação *wireless* pode ser definida como a transmissão de dados sem a utilização de fios, estando presente na maioria dos lugares, seja em uma simples mensagem de voz de um telefone, de e-mail, entre outros.

Existem várias opções de redes sem fio de longa distância. Uma das mais comuns é o Wi-Fi com a tecnologia 802.11ac (CARVALHO et al., 2022), que permite conexões de até 300 metros em áreas abertas. Além disso, existem outras tecnologias, como o 802.11ad (MATTOS et al., 2022), que pode oferecer distâncias de até 6 km.

Portanto, as redes Wi-Fi são uma das principais tecnologias de conexão sem fio que permite que dispositivos como computadores, smartphones, *tablets* e outros dispositivos se conectem à Internet. Em suma, as redes Wi-Fi são ideais para usuários que buscam uma solução eficiente e acessível para conectar dispositivos remotamente ou ainda dispositivos IoT. Além disso, elas também permitem que usuários compartilhem arquivos e acessem a Internet, o que torna a experiência de usuário mais prática e intuitiva.

## 2.6 Soluções IoT

IoT é um paradigma baseado na integração de uma variedade de processos envolvendo sensores, ferramentas e equipamentos do dia-a-dia, denominados objetos ou "coisas", potencializados pelo poder de computação e recursos de rede, que podem interagir uns com os outros e desempenhar um papel importante, resolvendo os mais variados tipos de problemas (ČOLAKOVIĆ; HADŽIALIĆ, 2018).

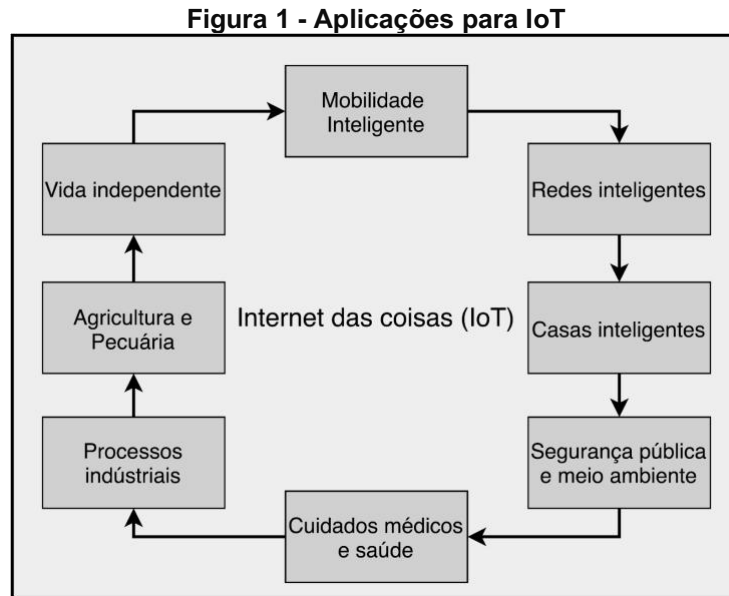
Nas últimas décadas houve uma expansão significativa na agricultura, caracterizada pela extensão de áreas, aumento de produção e uso de tecnologias (SUNDMAEKER et al., 2016), oferecendo novos modelos de negócio com surgimento de potenciais soluções IoT (LANGER, 2021). Ainda nesse contexto, temos o conceito *SmartFarming* (Agricultura Inteligente) caracterizado como:

Um processo baseado em tarefas de gerenciamento que não se limitam apenas ao local, mas também nos dados, aprimorados pelo conhecimento do contexto e da situação, acionado por eventos em tempo real, utilizando de recursos que geralmente incluem assistência inteligente na implementação, manutenção e uso da tecnologia (SUNDMAEKER et al., 2016).

A IoT é apontada por Ahmed, De e Hussain (2018), como a principal responsável em proporcionar uma nova dimensão na agricultura inteligente, sendo ela responsável por conectar propriedades agrícolas de maneira eficiente, auxiliar os agricultores, os propiciando acesso a dados abundantes de temperatura, fertilizantes usados, volume de água utilizado, entre outros, por meio de sensores nas áreas cultivadas e nos maquinários utilizados (LANGER, 2021).

A IoT possibilita aos agricultores a tomada de decisões mais informadas e precisas, pois os dados coletados podem ser usados para monitorar as condições climáticas, a qualidade do solo e as necessidades nutricionais das plantações. Isso permite que os agricultores possam identificar problemas antes mesmo que eles se tornem aparentes, otimizando assim o uso de recursos como água e fertilizantes (AHMED; DE; HUSSAIN, 2018).

Khanna e Kaur (2019) apresentam um estudo, onde diversas áreas de aplicação de soluções IoT são apresentados, dentre as quais podem ser encontradas a agricultura, pecuária, saúde, casas inteligentes, entre outras (KHANNA e KAUR et al, 2019). A Figura 1 mostra o estudo proposto pelos autores.



Fonte: Adaptado de Khanna e Kaur et al. (2019)

O potencial de integração da IoT é fundamental para a viabilidade de aplicações tecnológicas. Com o desenvolvimento das redes de computadores, hardware e software, foi possível que essa integração começasse dentro dos sistemas de computador. Dessa forma, “a tecnologia embarcada nos maquinários e no ciclo produtivo na agricultura intensiva vai ao encontro da utilização do IoT” (ROSA, 2017).

## 2.7 Sistemas embarcados

Sistemas embarcados consistem em uma combinação de hardware, software e possíveis componentes adicionais mecânicos, desenvolvidos para a execução de uma função dedicada (LI, 2003; STALLINGS, 2008). Esses sistemas computacionais aplicados diferem de sistemas computacionais de propósito geral, como computadores pessoais ou supercomputadores, apresentando maiores limitações de funcionalidades de hardware e de software (NOERGAARD, 2005).

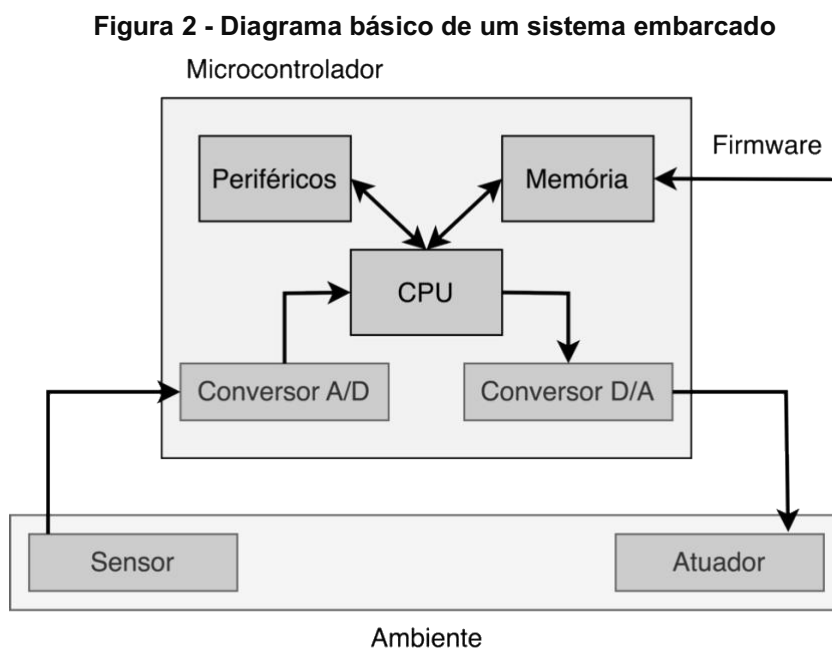
Sistemas embarcados representam plataformas geralmente desenvolvidas para tarefas específicas. Por exemplo, sistemas de controle industrial, robótica, veículos automotores, aviões, navios, sistemas médicos, dispositivos portáteis, telecomunicações, eletrônica de consumo, sistemas de segurança, entre outros.

São projetados para serem estáveis, confiáveis, facilmente controláveis e possuem baixo consumo de energia. Também são projetados para serem flexíveis e

escaláveis, para que possam ser adaptados a diferentes aplicações (MOREIRA, 2007). Geralmente, estes sistemas operaram com baixa latência, ou seja, eles têm que reagir rapidamente a qualquer mudança externa. Esta especificação faz com os sistemas desenvolvidos possam ser altamente otimizados uma vez que os limites de tarefas a serem executadas é bem definido (BERGER, 2002).

Segundo Buttazzo (2006) sistemas embarcados dividem-se em propriedades importantes, tais como: recursos limitados, onde são desenvolvidos sobre restrições de espaço, peso e energia, impostos pela aplicação; sensíveis a custo, pois frequentemente apresentam restrições devido à produção em massa e grande competição industrial; as limitações de tempo real, onde a maioria dos dispositivos embarcados interage com o ambiente e deve reagir a eventos externos e executar atividades computacionais dentro de restrições precisas de tempo; também apresentam comportamento dinâmico, que consistem de dezenas ou centenas de tarefas concorrentes que interagem entre si para o uso de recursos compartilhados; e também diferentes processadores, pois sistemas embarcados são suportados por uma grande quantidade de processadores e arquiteturas.

A Figura 2, adaptada de Chase (2010) exemplifica um sistema básico que compõe um sistema embarcado.



Fonte: Adaptado de CHASE (2010)

No que se refere a limitações de tempo real, diz-se que são sistemas capazes de processar dados e gerar resposta dentro de restrições temporais, antes de um tempo máximo pré-determinado (AROCA, 2008). Os sistemas que operam em tempo real incluem aqueles que dependem não apenas de resultados computacionais corretos, mas também do tempo em que esses resultados são produzidos. (RAMAMRITHAM; STANKOVIC, 1994).

Portanto, sistemas embarcados são sistemas informáticos autônomos e independentes que são geralmente usados para monitorar ou controlar um dispositivo ou sistema. Eles são normalmente acoplados diretamente ao dispositivo ou sistema e contém o hardware e software necessários para fazer o dispositivo funcionar, podendo ser utilizados em diversas áreas como controle de equipamentos industriais, controle de veículos, sistemas de controle de processos, monitoramento ambiental, ou ainda, como proposto, o monitoramento climático da troposfera local.

### **2.7.1 Hardware embarcado**

O processador é a principal unidade funcional de um sistema embarcado, sendo responsável por processar instruções e dados. Dispositivos eletrônicos contêm no mínimo um processador mestre, que atua como unidade de controle central, e podem possuir outros processadores adicionais que são controlados ou operam conjuntamente com o processador central (NOERGAARD, 2005).

A maioria dos sistemas embarcados utiliza microcontroladores ao invés de microprocessadores. Os microcontroladores habitualmente contêm a maioria dos periféricos e da memória do sistema integrados num mesmo chip, enquanto os microprocessadores praticamente não possuem periféricos (BERGER, 2002; NOERGAARD, 2005). Assim, um microcontrolador oferece maior desempenho, pois não requer a conexão com dispositivos externos para realizar os processos, como é o caso do microprocessador.

Além disso, os microcontroladores também são mais eficientes em termos de energia, pois possuem menos periféricos, o que significa que consomem menos energia. Por outro lado, os microprocessadores normalmente possuem maior desempenho e capacidade de processamento do que os microcontroladores. Além disso, os microcontroladores são mais compactos e,conseqüentemente, menos



custosos. Por essas características, são frequentemente usados em sistemas embarcados, que possuem exigências de desempenho, custo e tamanho reduzidos.

### 2.7.2 Software embarcado

Atualmente, o software é um componente essencial no desenvolvimento de sistemas embarcados, sendo incomum encontrar produtos controlados apenas por hardware (CHARRETTE, 2005). Sistemas embarcados envolvem muito mais recursos de computação, e com natureza diferente da computação tradicional (WOLF, 2007). O software embarcado é usado para controlar o hardware, a fim de realizar tarefas específicas, como a leitura de sensores, operações de controle e processamento de dados (CHARRETTE, 2005). O software embarcado precisa ser altamente confiável e seguro para garantir que as operações sejam realizadas de forma precisa. O software embarcado também precisa ser projetado para suportar ambientes com limitações em termos de memória, processamento e energia (WOLF, 2007).

Assim como os computadores pessoais, os sistemas embarcados também têm se tornado mais utilizados nos últimos anos, beneficiando cada vez mais pessoas. Desde terminais bancários de caixas eletrônicos a aparelhos eletrodomésticos, diariamente as pessoas são beneficiadas pelos serviços que esse tipo de sistema oferece (CAVALCANTE; BARROS, 2020). Desse modo, os softwares embarcados devem oferecer confiabilidade no seu funcionamento, evitando o prejuízo das pessoas que utilizam os sistemas e dependem deles.

Além disso, Knight (2002) ressalta que o software exerce papel importante na confiabilidade, na segurança, na integridade, na manutenção e na confidencialidade do sistema embarcado. Segundo Lee (2002), o software embarcado não é apenas o software em um pequeno computador, apresenta também características especiais como: a) Precisão temporal: softwares embarcados precisam interagir com o ambiente com restrições de tempo; b) Concorrência: o software embarcado deve reagir simultaneamente a estímulos de redes de comunicação e de uma variedade de sensores, e ao mesmo tempo, controlar atuadores; c) Operação contínua: o software embarcado não deve interromper a operação ou ficar bloqueado aguardando eventos que não ocorreram; d) Heterogeneidade: o software embarcado combina diferentes estilos de implementação, linguagens de programação e deve conviver com eventos

periódicos e esporádicos; e) Reatividade: reagem continuamente ao ambiente na velocidade do ambiente.

## **2.8 Inteligência artificial**

Desde a famosa reunião de Dartmouth em 1955, quando o termo "inteligência artificial" (IA) foi cunhado (RUSSELL; NORVIG, 2010), o impacto da IA nos negócios e na agricultura passou por vários estágios, incluindo longos períodos de financiamento reduzido para projetos de pesquisa e baixas expectativas para investimentos a longo prazo, culminando nas altas expectativas de hoje. A atual fase otimista é sustentada por inúmeros fatores, como a grande popularização do conceito, que possibilitam a implementação de aplicações práticas em larga escala para a IA (MEGETO et al., 2020).

Inteligência artificial é o termo usado para descrever a capacidade de um computador ou outra máquina para realizar tarefas que normalmente requerem inteligência humana, como tomar decisões complexas, reconhecer padrões e aprender. A inteligência artificial é desenvolvida usando algoritmos de aprendizado de máquina, que permitem que um computador aprenda por meio de dados e experiências (LUDERMIR, 2021).

Pode-se dizer que o campo de IA tem como objetivo, o contínuo aumento da inteligência do computador. Para este fim, é importante desenvolver técnicas que sejam suportadas por computador, emulando algumas capacidades específicas para tal finalidade. Esta coleção inclui a capacidade de resolução de problemas, processamento de Linguagem Natural, visão e robótica, sistemas especialistas e aquisição de conhecimento, metodologias de representação de conhecimento (RUSSELL; NORVIG, 2010).

Portanto, a inteligência artificial torna-se uma tecnologia emergente que altera consideravelmente os hábitos e comportamentos não só humanos, mas também os métodos de implantação e manejo dos sistemas de produção vegetal e animal. O desenvolvimento de ferramentas e máquinas baseadas em IA torna o sistema agrícola mais eficaz em termos de produção, monitoramento em tempo real e comercialização de produtos. Por exemplo, os sistemas de IA podem ser usados para monitorar as condições climáticas no local, bem como para detectar doenças e pragas que possam

afetar as culturas. Além disso, os agricultores podem usar sistemas baseados em IA para planejar melhor sua produção, com base nas condições climáticas e nos dados históricos disponíveis.

### 2.8.1 Aprendizagem de máquina

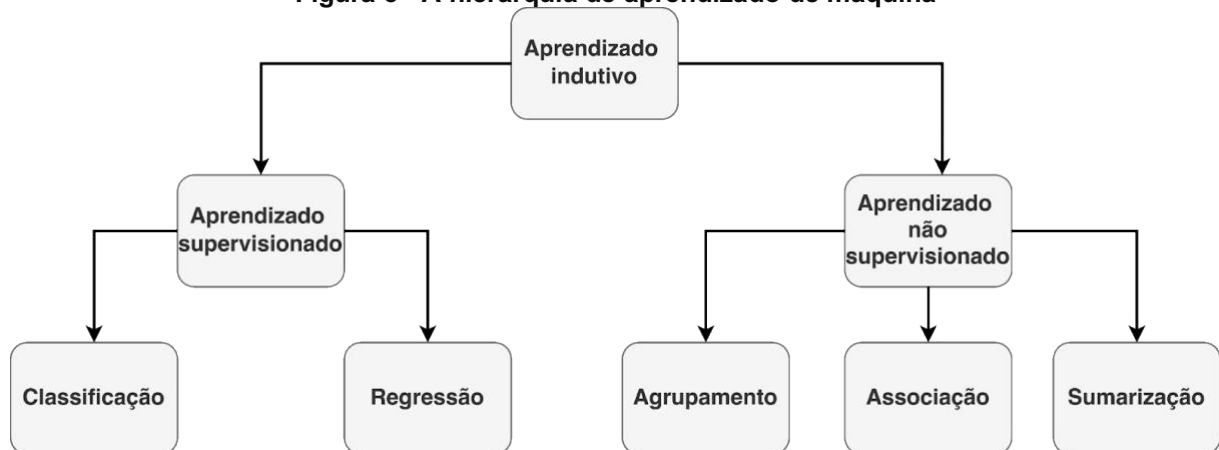
O aprendizado de máquina é uma área da inteligência artificial que visa desenvolver técnicas computacionais para aprender e edificar sistemas a fim de adquirir conhecimento automaticamente (MONARD; BARANAUSKAS, 2003). Isso leva ao desenvolvimento de programas que podem aprender utilizando uma coleção de dados que representam experiências anteriores (CERRI; CARVALHO, 2017).

Em outras palavras, o aprendizado de máquina é o processo de criar algoritmos que podem aprender com seu próprio desempenho, usando modelos matemáticos previamente definidos. O objetivo é alcançar a generalização dos conhecimentos adquiridos, ou seja, a capacidade de aplicar as informações aprendidas nas novas situações.

Diferentes sistemas de aprendizado de máquina compartilham algumas características que permitem que sejam categorizados de acordo com a linguagem de descrição usada, modo, paradigma e estilo de aprendizado. Um método de inferência lógica conhecido como indução é usado na hierarquia de aprendizado para chegar a conclusões gerais sobre um determinado conjunto de exemplos. A aprendizagem induzida pode ser dividida em aprendizagem supervisionada e não supervisionada, uma vez que é realizada usando exemplos fornecidos por processos fora do sistema de instrução.

O algoritmo de aprendizado ou indutor recebe um conjunto de amostras de treinamento para as quais o nome da classe correspondente é conhecido. Em geral, cada instância é descrita por um vetor de valores de recursos ou atributos e um rótulo de classe associada. O objetivo do algoritmo de indução é criar um classificador que consiga identificar corretamente classes de novas amostras que ainda não foram identificadas, ou seja, amostras sem rótulo de classe (MONARD; BARANAUSKAS, 2003). A Figura 3 exemplifica os níveis de hierarquia de aprendizado de máquina.

**Figura 3 - A hierarquia de aprendizado de máquina**



Fonte: Adaptado de Monard e Baranauskas (2003)

Desse modo, dentro do AM, existem dois tipos principais de tarefas, as descritivas e as preditivas. Nas tarefas descritivas, busca-se o desenvolvimento de algoritmos que descreverão os dados, entre as tarefas descritivas, uma das principais é o agrupamento de dados (FORGY, 1965; HORTA; CAMPELLO, 2012; KOHONEN, 1990), que busca separar os dados de maneira que os dados semelhantes fiquem em um mesmo grupo.

De maneira geral, buscam-se grupos cujas distâncias entre seus membros sejam minimizadas, maximizando ao mesmo tempo, a distância entre os grupos. Assim, as distâncias entre os dados de um mesmo grupo devem ser menores do que as distâncias entre dados em grupos diferentes (CERRI; CARVALHO, 2017).

As tarefas preditivas podem ser divididas em tarefas de classificação e tarefas de regressão. Nas tarefas de classificação, buscam-se atribuir categorias predefinidas a dados. Dessa forma, por meio dos atributos de entrada, o sistema é capaz de aprender a distinguir parâmetros e resultar em atributos de saída (CERRI; CARVALHO, 2017). Já em tarefas de regressão, o objetivo é prever o valor de uma determinada variável numérica, ou seja, um atributo de saída, uma vez que analisada determinados atributos de entrada.

### 2.8.2 Aprendizagem supervisionada

Os algoritmos para aprendizado supervisionado relacionam uma instrução a uma entrada baseada em dados aleatórios. Nesse caso, o usuário alimenta o

algoritmo com pares de entradas e saídas conhecidas, muitas vezes na forma de vetores. Cada saída recebe um rótulo, que pode ser uma classe ou um valor numérico. O algoritmo determina uma forma de prever qual o rótulo de saída com base em uma entrada forte.

Quando a saída for de um conjunto finito de valores, o problema da aprendizagem será chamado de classificação, e será chamado de classificação booleana ou binária se houver apenas dois valores (RUSSELL; NORVIG, 2010). De maneira similar, o rótulo de saída pode ser um valor real. Neste caso, o algoritmo deve prever qual o valor desta temperatura para uma dada condição de entrada, sendo que a saída pode assumir qualquer valor real. Estes algoritmos são chamados de algoritmos de regressão (RUSSELL; NORVIG, 2010).

Ludermir (2021) explica a diferença entre algoritmos de classificação e regressão da seguinte forma:

O objetivo do algoritmo é construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados. Para rótulos de classe discretos, esse problema é chamado de classificação e para valores contínuos é classificado como regressão. Esse método de aprendizado é o mais utilizado (LUDERMIR, 2021).

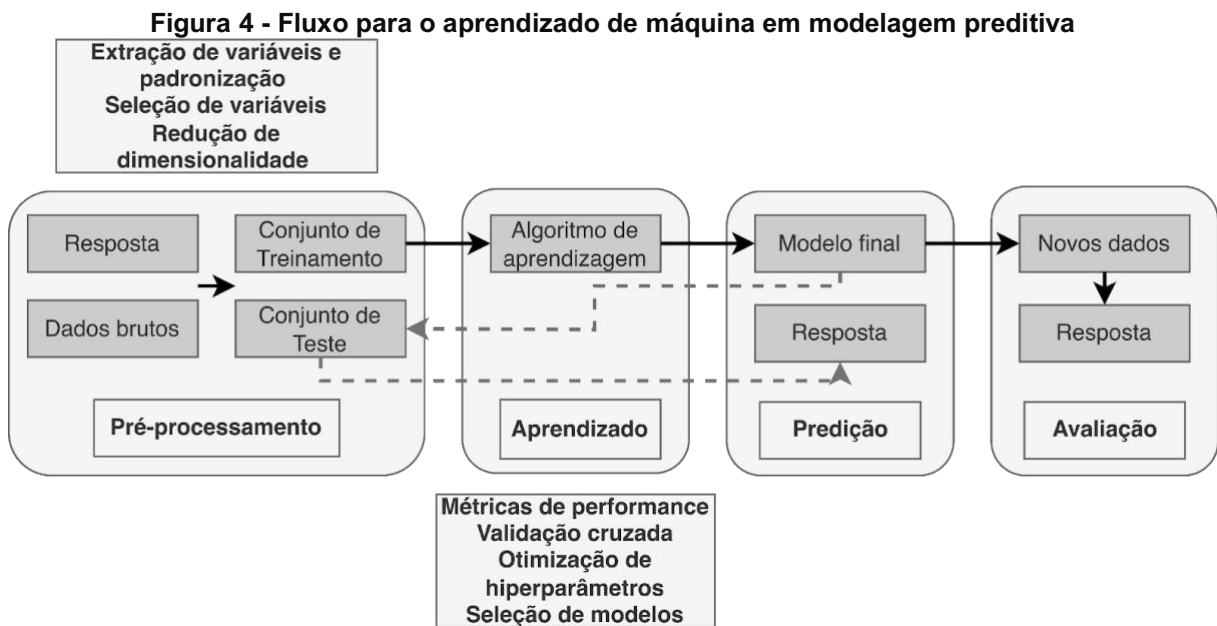
Portanto, algoritmos de regressão e classificação são ferramentas úteis para solucionar problemas complexos de aprendizagem de máquina. Eles podem ajudar a prever resultados futuros e a classificar dados de entrada de forma precisa. São frequentemente utilizados para fins de análise preditiva. Algoritmos de regressão e classificação podem ser aplicados em grandes conjuntos de dados para gerar métricas de desempenho precisas e fornecer *insights* valiosos. No entanto, deve-se ter cuidado especial ao selecionar os modelos e parâmetros apropriados para evitar sobreajustes.

### 2.8.3 Análise preditiva

A principal tarefa da análise preditiva é examinar fatos históricos ou experiências passadas para prever ou estimar eventos futuros ou desconhecidos e, ao fazê-lo, orientar a tomada de decisão atual. Dessa forma, os algoritmos tornam-se ferramentas essenciais para tornar os conjuntos de dados compreensíveis a ponto de

produzir regras preditivas. Essas ferramentas geralmente podem ser divididas em duas categorias no aprendizado de máquina: aprendizado supervisionado e aprendizado não supervisionado (HASTIE; TIBSHIRANI; FRIEDMAN, 2008; KUHN; JOHNSON, 2013).

Nos decorrer do trabalho, métodos supervisionados serão utilizados para a modelagem preditiva de respostas quantitativas e categóricas, dessa forma, as seguintes etapas de um sistema de aprendizado de máquina serão realizadas do seguinte modo: divisão aleatória do conjunto de dados em treinamento e teste, pré-processamento, aprendizado e seleção de modelos em dados de treinamento, predição da resposta de interesse em dados de teste e avaliação dos modelos selecionados (MIRJALILI; RASCHKA, 2017) como mostrado na Figura 4.



Fonte: Adaptado de Mirjalili e Raschka (2017)

A primeira etapa, referente à divisão aleatória do conjunto de dados original em treinamento e teste, sendo as mais usadas são 60:40, 70:30, ou 80:20, dependendo do tamanho inicial do conjunto, em geral, quanto maior o número de observações, maior será a proporção do conjunto inicial utilizada para o treinamento de modelos (MIRJALILI; RASCHKA, 2017). No entanto, é importante ressaltar que apenas o conjunto de treinamento é utilizado, garantindo ao final do processo, a aquisição de uma estimativa acurada da performance preditiva do modelo, quando aplicado a novas observações.

## 2.9 Algoritmos de aprendizagem de máquina

### 2.9.1 **DecisionTreeClassifier**

*DecisionTreeClassifier* é um algoritmo de aprendizado de máquina supervisionado utilizado para classificação. Ele trabalha criando árvores de decisão, que são diagramas que mostram fluxos partindo de um ponto específico e listando as decisões tomadas ao longo do caminho (“scikit-learndocumentation”, [s.d.]).

Este algoritmo normalmente é utilizado em qualquer tipo de classificação de dados, produzindo ótimos resultados. Estas árvores de decisão fornecem uma forma de prever a classe de uma nova instância a partir de um conjunto de características de treinamento (OKADA; NEVES; SHITSUKA, 2019). Além disso, ela é considerada como sendo uma técnica simples e relativamente fácil de ser empregada e que pode ser implementada por meio de diferentes algoritmos.

### 2.9.2 **DecisionTreeRegressor**

O *DecisionTreeRegressor* é um algoritmo para aprendizado de máquina supervisionado usado para prever variáveis contínuas. É baseado em árvores de decisão, que fornecem soluções de regressão por meio de caminhos de decisão baseados em árvores (“scikit-learndocumentation”, [s.d.]).

O *DecisionTreeRegressor* divide um conjunto de dados recursivamente em subconjuntos e utiliza a estratégia de dividirpara-conquistar: Um problema complexo é decomposto em subproblemas mais simples. De forma recursiva a mesma estratégia é aplicada a cada subproblema. A capacidade de discriminação de uma árvore vem da: Divisão do espaço definido pelos atributos em subespaços. A cada subespaço é associada uma classe (CREPALDI et al., [s.d.]).

### 2.9.3 Extra TreeClassifier

O método *Extra Trees*, também conhecido como *ExtremelyRandomizedTree*, é bastante similar ao método *Random Forest*. No entanto, existem algumas pequenas diferenças entre essas técnicas. Nesse caso, a principal preocupação é com os nós criados. Em *Random Forest*, o melhor nó é usado como ponto de partida para novos nós, enquanto em *Extra Trees*, um nó atípico é escolhido como ponto de partida para novos nós (SILVA, 2020).

Geurts, Ernst e Wehenkel (2005) observam que a precisão e a eficiência computacional do método *Extra Trees* são suas principais vantagens. Enquanto o *Random Forest* testa todas as divisões possíveis sobre uma falha das variáveis, o *Extra Trees* testa apenas as divisões possíveis sobre uma falha das variáveis, o que reduz o custo computacional e, conseqüentemente, o tempo de treinamento.

### 2.9.4 GaussianNaiveBayes (NB)

NaiveBayes (NB) é um método de classificação probabilística que também pode ser chamado de algoritmo bayesiano. Estes demonstram sua independência uns dos outros, pois cada atributo possui informações próprias e acaba não tendo influência nas informações dos demais (CARNEIRO et al., 2021).

Processos Gaussianos são um método genérico de aprendizado supervisionado projetado para resolver problemas de regressão e classificação probabilística (“scikit-learndocumentation”, [s.d.]). Segundo a documentação do *scikit-learn* as vantagens dos processos gaussianos são:

- A previsão interpola as observações (pelo menos para kernels regulares).
- A previsão é probabilística (Gaussiana) para que se possa calcular intervalos de confiança empíricos e decidir com base neles se deve-se reajustar (ajuste online, ajuste adaptativo) a previsão em alguma região de interesse.
- Versátil: diferentes kernels podem ser especificados. Kernels comuns são fornecidos, mas também é possível especificar kernels personalizados.



### 2.9.5 Análise discriminante linear

Análise discriminante linear ou *Linear Discriminant Analysis* é uma técnica estatística multivariada usada para categorizar e diferenciar objetos. Segundo Khattree e Naik (2000), essa técnica estatística multivariada examina a divisão de objetos de uma população em duas ou mais classes.

A discriminação ou separação, que é a parte exploratória da análise e envolve a busca de características que possam ser usadas para classificar os objetos em vários grupos previamente definidos. A definição de classificação ou alocação é um conjunto de regras que serão aplicadas na alocação de novos objetos (JOHNSON; WICHERN, 1999).

### 2.9.6 Regressão linear

Regressão linear ajusta um modelo linear com coeficientes para minimizar a soma residual dos quadrados entre os alvos observados no conjunto de dados e os alvos previstos pela aproximação linear. A regressão linear é usada para prever a variável dependente (Y) a partir de uma ou mais variáveis independentes (X). O objetivo da regressão linear é encontrar os melhores valores para os coeficientes de regressão, que minimizam a soma dos quadrados dos erros entre os valores previstos e observados ("scikit-learndocumentation", [s.d.]).

As regressões são simples de entender, pois descrevem equações matemáticas diretas que, na maioria dos casos, podem ser representadas graficamente. Modelos mais complicados são frequentemente chamados de soluções "caixa preta", pois pode ser difícil entender como eles realizam previsões ou como se comportam em determinadas situações. As regressões facilitam a extrapolação ou fazem previsões sobre valores fora do intervalo de nossos conjuntos de dados (MINEWISKAN, 2023).

### 2.9.7 Regressão logística

A regressão logística também é conhecida na literatura como classificação de máxima entropia ou classificador log-linear. Nesse modelo, as probabilidades que descrevem os possíveis resultados de uma única tentativa são modeladas usando uma função logística (“scikit-learndocumentation”, [s.d.]).

O objetivo do modelo de regressão logística para problemas de classificação é prever a probabilidade de cada observação pertencer a uma das classes da resposta desejada. A variável resposta do conjunto de treinamento é modelada usando a distribuição binomial, que tem como parâmetro, a probabilidade de ocorrer uma determinada classe.

É vital notar que a probabilidade estimada de uma determinada ocorrência deve ser restrita ao intervalo  $[0, 1]$  e deve ter uma correlação direta com os preditores medidos para cada observação do conjunto combinado de dados (KUHN; JOHNSON, 2013).

### 2.9.8 Support Vector Machines (One Class SVM)

Os algoritmos de aprendizagem de máquina (SVM) têm como principal objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (Vapnik, 1995).

Consiste em uma técnica computacional de aprendizado para problemas de reconhecimento de padrão. Introduzida por meio da teoria estatística de aprendizagem por Vapnik (1995), essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes.

### 2.9.9 Random Forest Classifier

Uma floresta aleatória é um estimador que ajusta vários classificadores de árvore de decisão em várias sub amostras do conjunto de dados e usa a média para

melhorar a precisão preditiva e controlar o ajuste excessivo (“scikit-learndocumentation”, [s.d.]).

Portanto, consiste em um sorteio aleatório de vários candidatos abertos para dividir cada nó da árvore, feito em cada nó. Com o uso desta técnica, várias combinações de variáveis podem aparecer em vários níveis em cada uma das árvores. Como resultado, a técnica torna-se mais sensível às interações entre as variáveis, bem como produz árvores decoradas, como resultado do processo de seleção aleatória utilizado para dividir o nó entre as diversas variáveis candidatas (BREIMAN, 1996).

#### 2.9.10 **Random Forest Regressor**

Um *Random ForestRegressor* é estimador que ajusta uma série de árvores de decisão de regressão classificação em várias sub amostras do conjunto de dados e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo (“scikit-learndocumentation”, [s.d.]).

*Random Forest* (floresta aleatória) é uma generalização da operação "árvore de decisão", na qual uma coleção de árvores de decisão (aleatórias) é usada para reduzir o sobreajuste (*overfitting*) de cada modelo de árvore individual gerado para os dados de entrada.

#### 2.9.11 **Support Vector Classifier**

Máquinas de vetores de suporte (SVMs) são um conjunto de métodos de aprendizado supervisionados usados para classificação e regressão (“scikit-learndocumentation”, [s.d.]). *Support Vector Machine* (SVM) é um algoritmo de aprendizado de máquina supervisionado que pode ser utilizado para desafios de classificação ou regressão. Seu foco é no treinamento e classificação de um *dataset*. Suas principais vantagens são:

- Eficiente em espaços dimensionais elevados.

- Eficaz nos casos em que o número de dimensões é maior que o número de amostras.
- Usa um subconjunto de pontos de treinamento na função de decisão (chamados de vetores de suporte), portanto, também é eficiente em termos de memória.
- Versátil: diferentes funções do Kernel podem ser especificadas para a função de decisão. Kernels comuns são fornecidos, mas também é possível especificar kernels personalizados.

## 2.10 Banco de dados

Dados podem ser armazenados das seguintes maneiras: utilizando-se banco de dados ou então arquivos de dados permanentes, ou seja, planilhas (SILBERSCHATZ, KORF; SUDARSHAN, 2012).

As características das Planilhas refletem o fato de terem sido concebidas a pensar no utilizador (ORACLE, 2023). Eles são ideais para um único usuário ou um pequeno grupo de usuários que não requerem manipulação de dados complexos. Por outro lado, os bancos de dados destinam-se a manter coleções muito maiores de informações organizadas, às vezes em quantidades enormes.

Os bancos de dados permitem que vários usuários acessem e consultem os dados de forma rápida e segura, usando lógica e linguagem altamente complexas. Martins e Guarienti (2019) explicam que com os mesmos é possível termos as seguintes vantagens: Controle centralizado de dados: os dados ficam localizados em um único local e isso facilita o controle e acesso; Controle da redundância: como os dados estão centralizados existe otimização e redução do espaço de armazenamento e controle de redundância; Compartilhamento de dados: com a utilização de um banco de dados sem redundância, o espaço de armazenamento é otimizado e facilita o compartilhamento de dados; Facilidade de acesso aos dados: estabelecimento de padrões devido a centralização dos dados e inter-relação de todos os registros; Independência de dados: os dados são independentes para cada registro dentro do Banco de Dados.

Depois de construído e preenchido com dados, o banco de dados tem um objetivo específico e simboliza um mínimo universo onde o interesse dos usuários em

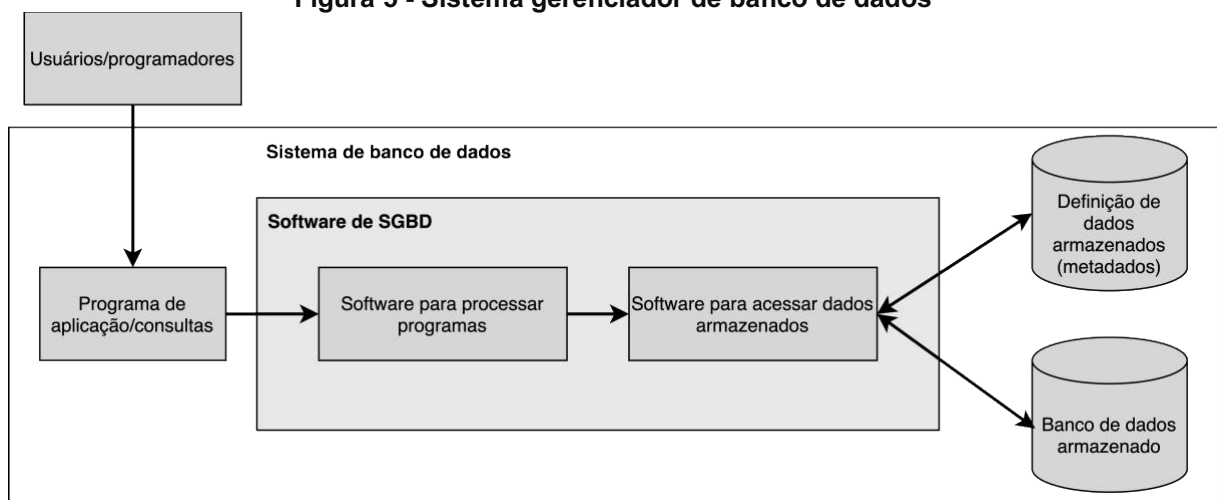
determinadas propriedades do objeto para processamento computacional é levado em consideração (ELMASRI; NAVATHE, 2011).

Um banco de dados pode ser visto como uma coleção de dados relacionados, que devem estar organizados para facilitar a busca e atualização desses dados. Os dados devem ter significado implícito e se referirem a fatos (FRANÇA; JÚNIOR, 2015).

Dessa forma, os SGBDs facilitam a conversão e a reorganização do Banco de Dados (MARTINS; GUARIENTI, 2019). Segundo Date (2004), um SGBD é um Sistema Gerenciador de Banco de Dados de propósito geral usado para manipular bancos de dados. Ele torna possível definir, construir e gerenciar um banco de dados para uma variedade de aplicações. Um SGBD tem uma estrutura conceitual, uma linguagem para definir dados, uma linguagem para manipular dados e utilidades significativas.

A Figura 5 mostra o fluxo de funcionamento de um SGBD, cujo qual é responsável por receber as solicitações de acesso aos dados do usuário, interpretar e validar essas solicitações, processar as informações e, por fim, enviar os resultados para o usuário.

**Figura 5 - Sistema gerenciador de banco de dados**



Fonte: Adaptado de FERRÉ (2023)

Portanto, um banco de dados tende a mostrar sua utilidade na gestão dos recursos naturais. O armazenamento dos dados climáticos permite que os agricultores tomem decisões assertivas sobre quando, por exemplo, plantar, pulverizar, irrigar e

fertilizar seu cultivo. Isso também pode auxiliar na identificação de possíveis problemas ambientais antes que se tornem graves.

## 2.11 Aplicações Web

Diferente das aplicações convencionas, que se desenvolvem ao longo de lançamentos previstos, cronologicamente espaçados, as aplicações *Web* evoluem constantemente, estando sujeitas a mudanças devido a evolução tecnológica e a volatilidade dos usuários *Web*, surgindo a situação de competitividade (KAPPEL et al., 2003).

Os aplicativos na *Web* são conhecidos por serem sistemas ou softwares informatizados que utilizam uma arquitetura distribuída, como o *Hypertext Transfer Protocol* (HTTP), podendo, portanto, ser acessados pelos usuários por meio de um navegador, também conhecido como navegador de internet (FILHO, 2019).

Para KAPPEL et al., (2003), desenvolvedores de aplicações *Web* devem preocupar-se com condições, riscos e incertezas, as quais não pertencem a softwares tradicionais como:

- Equipe de desenvolvimento: o desenvolvimento de aplicações *Web* envolve uma mistura de editores de impressão, autores, desenvolvedores de software, especialistas em marketing, designers de arte. Geralmente membros mais jovens, que estão em busca de inovações, não apenas aderindo às convenções;
- Ambiente de desenvolvimento: a infraestrutura deve ser volátil e heterogênea, pelo fato do desenvolvimento de aplicações *Web* contarem com variados componentes, como servidor *Web*, servidor de aplicação, banco de dados, editores de publicação, dentre outros;
- Integração com sistemas legados: geralmente aplicações *Web* necessitam se integrar com sistemas legados, porém muitas vezes estes sistemas são pouco documentados e modificados sem aviso prévio, interferindo na qualidade das aplicações *Web*;
- Processo: os processos para desenvolvimento de aplicações *Web* geralmente estão em constantes mudanças, em razão do crescente desenvolvimento tecnológico, novas tendências, exigências voláteis e cronogramas rígidos.

Portanto, sistemas *Web* são sistemas que usam servidores web para fornecer conteúdo a usuários finais por meio de um navegador. O conteúdo pode ser qualquer tipo de informação, como texto, imagens, áudio, vídeo, etc. Oferecem ainda aos usuários um acesso conveniente aos recursos de informação e serviços que eles

desejam. Por exemplo, os usuários podem usar os sistemas *Web* para buscar, visualizar e interagir com conteúdos, aplicativos, serviços e outros recursos. Neste contexto, os sistemas de informação são referidos como aplicações *Web*.

Não obstante, a utilização de um painel de controle, em sistemas web, facilitam a visualização e a interpretação das informações mostradas, possibilitando o entendimento e auxiliando na tomada de decisão (BORGES et al, 2020). O termo *Dashboard* é oriundo dos painéis que são utilizados em carros e aviões, onde tem a finalidade de apresentar informações ao usuário, sem necessidade de interpretações e análises cruzadas, sendo disponibilizadas e organizadas de forma limpa e útil (FEW; EDGE, 2007).

Malik (2005) refere-se a *Dashboard* como “uma interface de computador rica com gráficos, relatórios, indicadores visuais e mecanismos de alerta que são consolidados em uma plataforma de informação dinâmica e relevante”. Como resultado, seu uso permite que os usuários analisem dados de várias perspectivas e níveis. *Dashboard* é uma ferramenta de comunicação que consolida métricas em uma única visão, processa e apresenta dados dinamicamente e gera alertas em resposta a mudanças nos termos e condições dos provedores de dados (BORGES et al, 2020).

Chen (2010) afirma que “a visualização da informação está relacionada com a concepção, desenvolvimento e aplicação de representações de informações gráficas interativas geradas por computador”. Dessa forma, para que a interpretação dos dados seja útil, é necessário o uso de tecnologias que permitam interagir com as informações observadas (BORGES et al, 2020).

### 3 MATERIAIS E MÉTODOS

#### 3.1 Descrição da localidade

A propriedade parceira onde foi desenvolvido o trabalho de pesquisa está localizada no distrito de Alto Alegre no município de Céu Azul, estado do Paraná, cujas coordenadas geográficas são 25°05'05.6"S 53°47'57.9"W, a uma altitude de aproximadamente 663 metros ao nível do mar e ficando a aproximadamente 10km do centro urbano no município. Possui cerca de 96 Hectares, sendo as principais atividades agrícolas as culturas de soja, milho e trigo.

**Imagem 1 - Município de implantação do projeto**



Fonte: CÉU AZUL (2023)

#### 3.2 Implantação da rede wireless

Para a realização da pesquisa, a conectividade dos equipamentos a internet é essencial. Para isso, foi utilizada uma torre estaiada, de aproximadamente 25 m de altura, para a distribuição do sinal de forma omnidirecional, ou seja, uniforme em todas as direções, com equipamentos de distribuição para redes externas. A mesma já estava presente na propriedade, pois trata-se de um ponto de distribuição de internet



de um provedor local. A Fotografia 1 mostra a torre utilizada para a distribuição do sinal na localidade.

**Fotografia 1 - Torre de distribuição de internet**



**Fonte: Aatoria própria (2023)**

Dessa forma, o provedor, além de ceder a utilização da torre que já estava na propriedade, e o compartilhamento da eletricidade necessária, gentilmente disponibilizou também o acesso à internet, e possíveis equipamentos que fossem necessários para a distribuição do sinal, possibilitando maior engajamento da comunidade na pesquisa.

A conexão com a internet utilizada foi de 35 Mb, em testes preliminares, foi constatado que 5 Mb seria o suficiente para o funcionamento dos equipamentos, porém, foi solicitado uma maior velocidade como forma de precaução contra possíveis oscilações que poderiam ocorrer no local, como por exemplo a perda natural de pacotes de transmissão devido a distância da comunidade do centro de distribuição da empresa. A Imagem 2 mostra os equipamentos utilizados para a distribuição do WI-FI na localidade.

**Imagem 2 - Equipamentos utilizados para o WI-FI local**




**Fonte: Ubiquiti (2023)**

Esses equipamentos utilizam-se da tecnologia TDMA (*Time Division Multiple Access*), que é um protocolo de comunicação usado para acesso compartilhado a um meio de transmissão de dados. É um dos muitos protocolos de acesso usados em redes sem fio como a rede UbiquitiAirMax. Com o TDMA, os usuários são divididos em grupos que compartilham o mesmo canal de comunicação (MELLO, 2002).

Cada grupo recebe um período de tempo que é usado para enviar e receber dados. Isso permite que vários dispositivos compartilhem o mesmo espectro de frequência, aumentando a capacidade da rede. Além disso, o TDMA fornece a capacidade de gerenciar o tráfego de dados enquanto dá prioridade aos usuários mais críticos.

Dessa forma, foi possível atingir distâncias significativas em toda a propriedade rural ampliando as possibilidades de utilização do projeto em diferentes pontos no cultivo. Na Imagem 3 está disposta a área de cobertura da internet em relação ao espaço territorial da propriedade, onde o azul representa alta intensidade de sinal.

**Imagem 3 - Área de abrangência do WI-FI**



**Fonte: Uisp(2021)**

A distância entre os dois pontos representados na Imagem 2, corresponde a aproximadamente 1200 metros. Vale lembrar que a propriedade possui 96 hectares, e como visto, o sinal ultrapassa os limites das divisas, apresentando bom funcionamento nas propriedades vizinhas. Nos locais da fazenda onde o sinal não atinge, declives acentuados estão presentes, prejudicando assim a distribuição nas partes mais baixas do relevo.

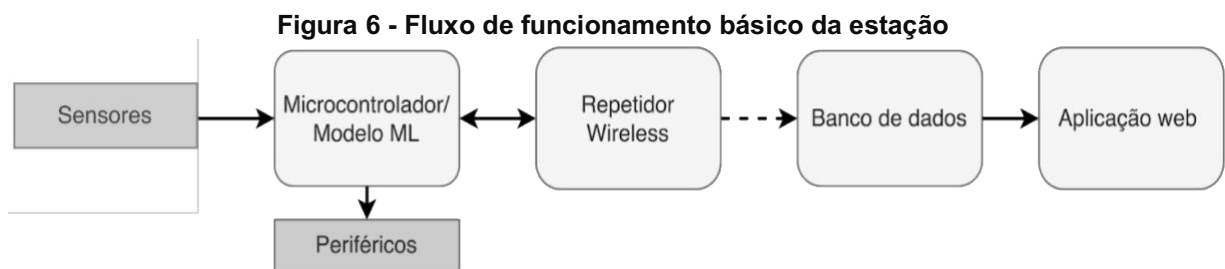
### **3.3 Desenvolvimento da estação meteorológica**

Neste projeto, utiliza-se uma estação automática, cuja coleta de dados é automatizada. Nesse tipo de estação os sensores emitem sinais elétricos, que são captados e enviados para um sistema de banco de dados, possibilitando que o armazenamento e o processamento dos dados sejam informatizados e acessados posteriormente (BALBINO, 2016).

Também foi utilizado um repetidor de sinal Wireless (Intelbras *hotspot* 300), visando aumentar a qualidade da conexão com a internet e maior abrangência do sinal para os usuários locais, possibilitando a conexão de outros dispositivos próximos a

estação, como *tablets*, *smartphones*, *notebooks*, ou qualquer outro dispositivo passível de funcionamento na área de alcance do equipamento.

A Figura 6 mostra o fluxo de funcionamento da estação meteorológica, onde os seus periféricos, sensores e atuadores, estão conectados ao microcontrolador, que por sua vez conectado ao repetidor Wireless enviando os dados coletados para o banco de dados.




Fonte: Autoria própria (2022)

A estação em questão mede a temperatura, umidade relativa, pressão atmosférica, velocidade e direção dos ventos e o índice pluviométrico, por não realizar as medições de radiação solar, classifica-se então como estação de segunda classe (BALBINO, 2016). Os sensores utilizados são o anemômetro para medir a velocidade do vento; termistor para medições de temperatura; umidade do ar e pressão atmosférica; pluviômetro para a precipitação de chuvas, anemoscópio que indica a direção do vento e sensor de umidade do solo.

O microcontrolador utilizado para o desenvolvimento do projeto é o Arduíno, equipamento este expresso por Banzi e Shiloh (2015), como "uma plataforma de computação física de fonte aberta, com base em uma placa simples de entrada/saída (input/output, ou I/O), assim como em um ambiente de desenvolvimento".

Também foi utilizado uma expansão (*Shields*) para a comunicação com a internet. Almagem 4 mostra o microcontrolador utilizado e a expansão responsável pela comunicação com a internet e o envio dos dados, respectivamente.

**Imagem4 - Black Board Mega 2560 R3 e Shield Ethernet W5500**



Fonte: Robocore (2023)


### 3.3.1 Sensores utilizados

Sensores são dispositivos que captam informações do ambiente e as convertem em sinais elétricos mensuráveis. Desse modo, diversos sensores foram utilizados para o desenvolvimento da estação, como o BME 280 para temperatura, umidade relativa e pressão atmosférica, sensor S12 para umidade do solo, pluviômetro automático de balança para o monitoramento de índice pluviométrico, anemômetro de concha para a velocidade dos ventos e anemoscópio para indicação da direção dos ventos, que serão demonstrados e explicados adiante.

### 3.3.2 Sensor BME280

Para o monitoramento de dados como, temperatura, umidade do ar e pressão atmosférica, utilizou-se o sensor BME 280 alocado em um abrigo, como demonstrado na Imagem 5.

**Imagem 5 - Sensor BME 280 e abrigo**



Fonte: Autoria própria (2023)

Para o melhor entendimento, é importante ressaltarmos alguns conceitos importantes sobre os dados captados pelo sensor BME 280, como por exemplo:

- Temperatura: Para Mendonça e Oliveira (2007), temperatura "é a medida do calor sensível nele armazenado, sendo comumente dada em graus Celsius, ou Fahrenheit e medida por termômetros".
- Umidade relativa do ar: Ayoade (2006) refere-se à umidade como "termo usado para descrever a quantidade de vapor d'água contido na atmosfera". Porém não abrange as outras formas nas quais a água pode estar presente na atmosfera, como na forma líquida (gotículas d'água) e na forma sólida (gelo).
- Pressão atmosférica: A força da gravidade é também responsável pelo "peso" da coluna de ar, ou seja, pela "pressão" que exerce sobre a superfície da Terra (CONTI e FURLAN, 2008).

### 3.3.3 Sensor de umidade do solo

Ainda quanto aos sensores, também foi utilizado um sensor de umidade de solo, tal sensor é um dispositivo utilizado para medir a quantidade de água disposta no solo. Almagem 6, mostra o sensor utilizado na estação.

**Imagem 6 - Sensor de umidade do solo S12**



Fonte: FERMARC (2023)

### 3.3.4 Pluviômetro automático de balança

Dentre os pluviômetros, o mais comum a ser utilizado é o pluviômetro automático de balança, que opera como uma gangorra posicionada sob o bico de um funil por onde toda a água pluvial coletada pelo aparelho é conduzida. A operação desse pluviômetro é basicamente um ímã acoplado à balança e uma chave magnética (MENEZES, 2019).

O mecanismo é acionado quando a quantidade de líquido em uma balança ou concha atinge o valor máximo; isso remove o líquido e prepara outra concha para receber líquido adicional por meio de um contato com relé magnético. A cada mudança de posição do mecanismo é causado um fechamento momentâneo da chave, produzindo um pulso elétrico que é transmitido ao microcontrolador (MENDEZ et al., 2013).

Fotografia 2 - Pluviômetro automático de balança



Fonte: Autoria própria (2023)

### 3.3.5 Anemômetro de concha e Anemoscópio

Os anemômetros são instrumentos utilizados para medir a velocidade do vento. Os principais tipos são os de concha, de hélice, de fio quente e os sônicos (SANCHES, 2020). Neste trabalho, foi utilizado um anemômetro de concha. Sua estrutura consiste em 3 conchas localizadas radialmente a 120 graus entre si montadas em um eixo



vertical com rolamentos de baixo atrito (SANCHES, 2020). O vento incide de forma diferente nas superfícies côncavas e convexas das conchas, girando o anemómetro proporcionalmente à sua velocidade. Um sensor detecta este movimento e os dados são processados (BURT, 2012).

Já um anemoscópio é um dispositivo que indica a direção do vento. Consiste basicamente em uma hélice de metal ou plástico ligada a um eixo e presa a um suporte. O eixo tem um ponteiro que oscila à medida que o vento sopra (SANCHES, 2020), indicando assim o sentido de origem. A Fotografia 3 mostra o posicionamento de um anemómetro e um anemoscópio na estação meteorológica.

**Fotografia 3 - Anemómetro e anemoscópio**



Fonte: Autoria própria (2023)

### **3.3.6 Cálculos efetuados pela estação**

Além de aprendizagem de máquina e leitura dos sensores, a estação efetua alguns cálculos e os envia para o banco de dados para futuras análises e comparação dos dados. São cálculos baseados nas leituras efetuadas em tempo real, como ponto de orvalho, altura da base das nuvens e sensação térmica. Os respectivos cálculos podem ser vistos a seguir.



### 3.3.6.1 Ponto de orvalho

A temperatura de ponto de orvalho é a temperatura à qual o ar úmido deve ser arrefecido, a pressão e razão de mistura constantes, para que atinja a saturação em relação à água. Portanto, o ponto de orvalho é entendido como a temperatura que o ar deve atingir para ocorrer a condensação da água (HOLLIMAN, 2010). O cálculo pode ser expresso da seguinte forma.

$$PO = (17.271 * T) / (237.7 + T) + \log (h * 0.01)$$

onde:

- PO = Ponto de orvalho (em °C);
- T = é a temperatura (em °C);
- h = é a umidade relativa (em %);

### 3.3.6.2 Altura da base das nuvens

A base da nuvem é a menor altitude da parte visível da mesma. A altura da base da nuvem pode ser medida usando um equipamento chamado de ceilômetro. Este dispositivo reflete um feixe de luz da base da nuvem e, em seguida, calcula sua distância usando triangulação ou tempo de viagem (CHRISTIE, 2023).

Porém, nem sempre é um dispositivo de fácil acesso. Dessa forma existe alternativamente outra possibilidade para efetuar o cálculo, onde a base da nuvem pode ser estimada a partir de medições da temperatura e umidade do ar, através da seguinte expressão:

$$h = 125 * (T - PO)$$

onde:

- h = Altura da base das nuvens (m);
- T = T é a temperatura (em °C);
- PO = Ponto de orvalho (em °C);

### 3.3.6.3 Sensação térmica

A sensação térmica (ST) é definida como a temperatura percebida pelos seres humano, onde calcula-se a combinação de temperatura do ar, velocidade do vento e umidade relativa. A fórmula para calcular a sensação térmica é expressa da seguinte maneira:

$$ST = 0,81 * T + 0,01 * h * (0,99 * V - 0,16) + 0,0038 * T * h$$

Onde:

- T é a temperatura (em °C);
- h é a umidade relativa (em %);
- V é a velocidade do vento (em m/s).

## 3.4 Pré-processamento

### 3.4.1 Levantamento dos dados históricos

Para Mendes e Miskulin (2017), a coleta de dados é um processo que visa reunir os dados para uso secundário por meio de técnicas específicas de pesquisa, esses dados são utilizados para tarefas de pesquisa, planejamento, estudo, desenvolvimento e experimentações. Segundo Marconi e Lakatos (2002), quando se referem à exploração técnica, sistemática e exata de uma pesquisa, destaca da seguinte forma:

O investigador, baseando-se em conhecimentos teóricos anteriores, planeja cuidadosamente o método a ser utilizado, formula o problema e a hipótese, registra sistematicamente os dados e os analisa com a maior exatidão possível. Para efetuar a coleta dos dados, utiliza instrumentos adequados, emprega todos os meios mecânicos possíveis, a fim de obter maior exatidão na observação humana, no registro e na comprovação de dados (MARCONI; LAKATOS, 2002).

Dessa forma, baseando-se em conhecimentos anteriores, utilizou-se dados históricos coletados diretamente ao INMET, provenientes da estação meteorológica automática situada no município de Maringá no Paraná, por apresentar equivalência do ponto de vista do gradiente térmico vertical e proximidade geográfica quando comparada com as demais estações disponíveis do instituto.

O gradiente térmico da atmosfera como um todo (Gradiente Real Observado, GRO) é variável, mesmo o sendo, normalmente situa-se em torno de  $-0,6\text{ }^{\circ}\text{C}$  a cada 100 metros de altitude (SOUZA, 2022). O município de Maringá está a 550 metros de altitude em relação ao nível do mar, e o local onde os experimentos foram realizados, em Céu Azul, também no Paraná, está a 663 metros em relação ao mesmo nível, sendo a distância entre os municípios de aproximadamente 320 km.

Os dados por sua vez datam do dia 21 de novembro de 2006 ao dia 30 de abril de 2022, totalizando aproximadamente 132.418 linhas e 18 colunas, contendo: data, hora (UTC), precipitação (mm), pressão atmosférica ao nível da estação (mB), pressão atmosférica máxima na hora anterior (mB), pressão atmosférica mínima na hora anterior (mB), radiação global ( $\text{KJ}/\text{m}^2$ ), temperatura do ar bulbo seco ( $^{\circ}\text{C}$ ), temperatura do ponto de orvalho ( $^{\circ}\text{C}$ ), temperatura do orvalho máxima na hora anterior ( $^{\circ}\text{C}$ ), temperatura do orvalho mínima na hora anterior ( $^{\circ}\text{C}$ ), temperatura máxima na hora anterior ( $^{\circ}\text{C}$ ), temperatura mínima na hora anterior (%), umidade relativa do ar (%), umidade relativa máxima na hora anterior (%), umidade relativa do ar mínima na hora anterior (%), direção horária do vento ( $^{\circ}$ ), rajada máxima do vento (m/s), velocidade horária do vento (m/s).

### **3.4.2 Exclusão dos dados incompletos**

Comumente, dados brutos raramente vêm na forma e formato necessários para o melhor desempenho de um algoritmo de aprendizado. Assim, o pré-processamento dos dados é uma das etapas mais importantes em qualquer aplicativo de aprendizado de máquina (MIRJALILI; RASCHKA, 2017). Portanto, é necessário considerar características pertinentes à dimensão do conjunto de dados (número de observações e de preditores disponíveis), à variável resposta (categórica ou contínua, balanceada ou desbalanceada, simétrica ou assimétrica) e aos preditores (variável contínua, contagem, variável categórica, variáveis correlacionadas/associadas,

escalas diferentes, presença de valores faltantes e de dados esparsos) (KUHN; JOHNSON, 2013; MIRJALILI; RASCHKA, 2017).

**Figura 7 - Exemplo de dados faltantes**

21/11/2006	01:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	02:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	03:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	04:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	05:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	06:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	07:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	08:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	09:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	10:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	11:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	12:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	13:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	14:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	15:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	16:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	17:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	18:00	0	950,3	950,8	950,3	2393,4	30,1	14,9
21/11/2006	19:00	-9999	-9999	-9999	-9999	-9999	-9999	-9999
21/11/2006	20:00	0	949,4	949,8	949,4	1543,7	30,7	15,4
21/11/2006	21:00	0	949,2	949,4	949,1	942,6	29,8	15,7

Fonte: INMET (2022)

Infelizmente, a maioria das ferramentas computacionais são incapazes de tratar esses valores imprecisos que podem produzir resultados imprevisíveis se os desconsiderados. Portanto, é fundamental tratá-los antes de prosseguir com análises adicionais. É importante também destacar que esse procedimento deve ser adotado antes da aplicação de técnicas utilizadas para a modelagem preditiva (MIRJALILI; RASCHKA, 2017), pois podem resultar em melhora da performance do modelo e/ou de sua estabilidade numérica (SANTOS, 2018).

### 3.4.3 Base de dados – *Dataset*

Uma base de dados é um conjunto de informações organizadas de forma a permitir que elas sejam facilmente acessadas, gerenciadas e atualizadas. Ela é usada para armazenar e recuperar informações relevantes para um aplicativo ou sistema. As bases de dados são frequentemente usadas para armazenar grandes quantidades de dados que podem ser facilmente consultados e manipulados.

Dessa forma, posteriormente à coleta de dados em formato CSV junto ao INMET, os dados foram separados em dois arquivos, um referente aos que são

essenciais para o treinamento de máquina para pulverização, nomeado como "SIM", e um para a não pulverização, nomeado como "NÃO". As informações utilizadas para a categorização foram: precipitação, temperatura do ar bulbo seco, umidade relativa do ar, e velocidade horária do vento, nessa ordem respectivamente.

No Quadro 1, encontra-se a expressão utilizada para separar dados para pulverização, representados pelo dígito 1, e não pulverização representados pelo dígito 0. Já a Imagem 7 mostra os dados já devidamente catalogados.

**Quadro 1 - Expressão utilizada para separar os dados preditivos**

=SE(E(A2=0; B2>=15;B2<=30; C2>=55; D2>=3; D2<=10); "1"; "0")

Fonte: Autoria própria (2023)

onde:

- A = Precipitação (mm);
- B = Temperatura (°C);
- C = Umidade (%);
- D = Vento (Km/h);

**Imagem 7 - Separação dos dados preditivos**

1	Precipitação	Temperatura	Umidade	Vento km/h	Pulverização
2	0	30,1	40	7,92	0
3	0	30,7	40	10,08	0
4	0	29,8	42	8,28	0
5	0	28,5	48	6,48	0
6	0	27,5	53	5,04	0
7	0	26,7	56	5,04	1
8	0	26,1	57	5,76	1
9	0	24,9	62	7,2	1
10	0	23,9	66	3,6	1
11	0	23,6	66	5,4	1
12	0	23,1	68	9,72	1
13	0	22,2	74	7,56	1
14	0	21,8	75	6,84	1
15	0	21,3	79	8,64	1
16	0	21,9	77	9,36	1
17	0	23,1	71	11,88	0
18	0	25,1	63	11,88	0
19	0	27	55	13,32	0
20	0	29,3	51	9,36	0

Fonte: Autoria própria (2023)

Como resultado do total de 121.095 linhas disponíveis, 83.806 linhas, cerca de 69,2% foram realocadas no arquivo "NÃO", e as outras 37.289 linhas,

representando 30,8% ficaram no dataset "SIM". As Imagens 8 e 9 mostram os dados já separados em *datasets* diferentes.

**Imagem 8 - Exemplo de dados aleatórios para pulverização, "SIM"**

1	0,26.7,56,5.04
2	0,26.1,57,5.76
3	0,24.9,62,7.2
4	0,23.9,66,3.6
5	0,23.6,66,5.4
6	0,23.1,68,9.72
7	0,22.2,74,7.56
8	0,21.8,75,6.84
9	0,21.3,79,8.64
10	0,21.9,77,9.36
11	0,26.5,55,3.96
12	0,25.9,56,4.32
13	0,24.6,63,4.68
14	0,24.9,63,6.84
15	0,20.9,92,7.2

Fonte: Autoria própria (2023)

**Imagem 9 - Exemplo de dados aleatórios para a não pulverização, "NÃO"**

1	0,30.1,40,7.92
2	0,30.7,40,10.08
3	0,29.8,42,8.28
4	0,28.5,48,6.48
5	0,27.5,53,5.04
6	0,23.1,71,11.88
7	0,25.1,63,11.88
8	0,27,55,13.32
9	0,29.3,51,9.36
10	0,30.6,45,11.88
11	0,31.3,40,5.76
12	0,32.4,35,5.04
13	0,33,34,6.84
14	0,31.8,34,8.28
15	0,32,29,9.36

Fonte: Autoria própria (2023)

Dessa forma, com o pré-processamento encerrado, temos dois arquivos distintos com um considerável volume de dados, onde então serão utilizados para o treinamento de máquina para os respectivos algoritmos apresentados. É importante ressaltar que as variáveis separadas e categorizadas, são baseadas nas informações fornecidas pela ANDEF (2004) para a aplicação de defensivos agrícolas.

## 3.5 Processamento

### 3.5.1 Ferramentas utilizadas para o treinamento de máquina

As ferramentas utilizadas foram Python como linguagem de programação e Jupyter como ambiente de desenvolvimento, dado a simplicidade de acesso, a fácil utilização e o bom desempenho das plataformas.

Python é uma linguagem de programação de código aberto, e suporta diversos paradigmas de linguagem, como orientação a objetos, programação estruturada, funciona, entre outras. Devido a grande facilidade e a alta gama de bibliotecas disponíveis, tornou-se a ferramenta mais utilizada em *Data Science* e Machine Learning (PROGRAMS, 2018).

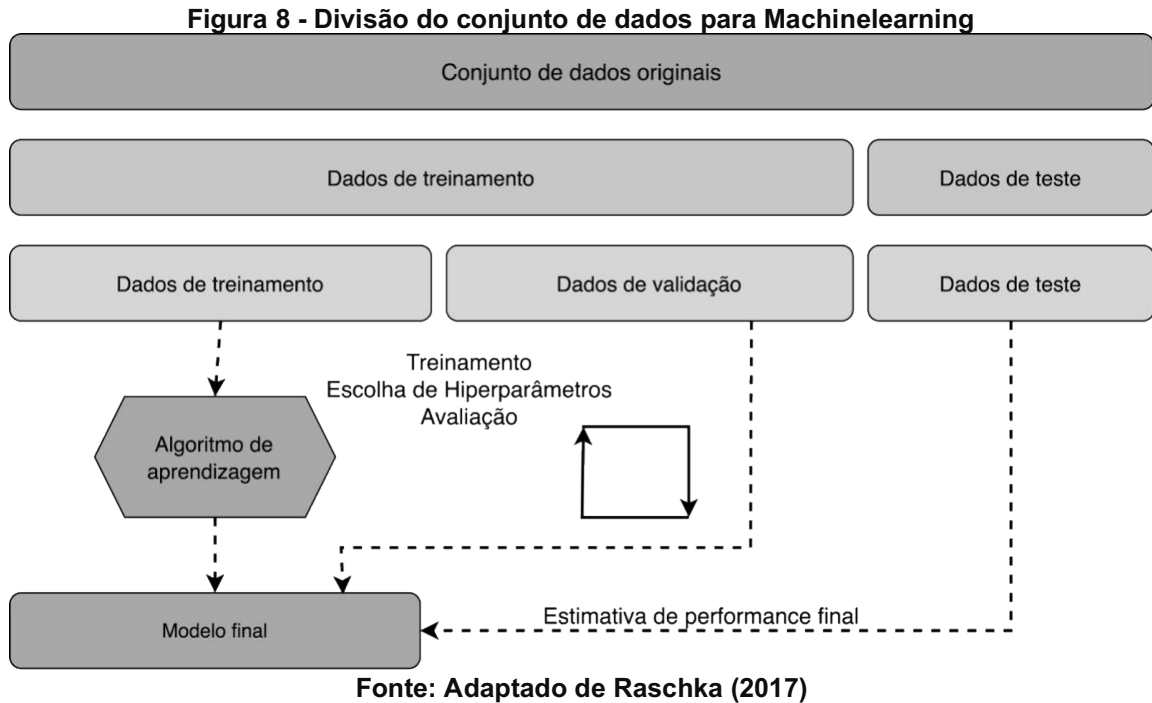
Já Jupyter Notebook é uma aplicação web, também, código aberto, que suporta linguagens como Python, R e Julia. Seu ambiente permite a execução dos códigos, apresentando resultados dos mais diversos processamentos disponíveis na ferramenta (JUPYTER, 2023).

### 3.5.2 Treinamento dos modelos

Em geral, selecionar e avaliar modelos constituem em dois principais objetivos do aprendizado de modelos preditivos. Inicialmente, o desempenho de vários modelos é avaliado com o objetivo de escolher aquele que apresenta o melhor desempenho. Em seguida, após a escolha de um modelo, busca-se estimar seu erro de predição (erro de generalização) em novas observações (HASTIE; TIBSHIRANI; FRIEDMAN, 2008).

Portanto, uma das principais estratégias para a seleção do modelo envolve, dividir aleatoriamente o pacote de treinamento em treinamento e validação. Dessa forma, o conjunto de dados original é dividido em três partes: treinamento, validação e teste. Os dados de treinamento serão usados para ajustar os modelos e os dados de validação serão usados para escolher um modelo com base em seu desempenho previsto. Por fim, os dados de teste serão utilizados para avaliar o erro de

generalização do modelo selecionado (HASTIE; TIBSHIRANI; FRIEDMAN, 2008). A Figura 8, a seguir, ilustra a divisão do conjunto de dados original.



Dessa forma, foram aplicados os algoritmos de treinamento conforme as possibilidades disponíveis e limitações impostas pelo hardware. No Quadro 2, estão demonstradas as importações das ferramentas necessárias para o início da execução do programa, sendo tomado como exemplo algoritmo do *Random Forest Classifier*.

**Quadro 2 - Bibliotecas para aprendizagem de máquina**

```
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score, f1_score, roc_auc_score,
recall_score, precision_score
from sklearn.model_selection import train_test_split
from glob import glob
from os.path import basename
import numpy as np
```

**Fonte: Eloquent Arduino (2022)**

onde:

- `from sklearn.ensemble import RandomForestClassifier` = Cria um classificador de floresta aleatória, que é um tipo de algoritmo de



aprendizado supervisionado usado para classificar dados. O algoritmo usa várias árvores de decisão ao invés de apenas uma, e cada árvore é treinada com uma amostra diferente do conjunto de dados.

- `fromsklearn.metricsimportaccuracy_score, f1_score, roc_auc_score, recall_score, precision_score` = Importa as métricas de avaliação de modelos de aprendizado de máquina da biblioteca *Scikit-Learn*. As métricas incluem precisão, recall, F1 score, acurácia e curva AUC.
- `fromsklearn.model_selectionimporttrain_test_split` = É usado para dividir um conjunto de dados em dois subconjuntos: um conjunto de treinamento e outro de teste. O `train_test_split` é uma função do *Scikit-Learn* que divide os dados em duas partes, usando uma proporção especificada. A proporção é usada para determinar a quantidade de dados no conjunto de treinamento e no conjunto de testes. Essa divisão permite que o modelo seja treinado com os dados do conjunto de treinamento e avaliado com os dados do conjunto.
- `fromglobimportglob` = `glob` é uma função que permite ao usuário localizar arquivos e diretórios.
- `fromos.pathimportbasename` = Importa o método `basename` da biblioteca `os.path`. O método `basename` retorna o nome do arquivo de um caminho.
- `importnumpy as np` = A biblioteca *Numpy* fornece uma série de ferramentas úteis para trabalhar com matrizes e vetores, bem como funções matemáticas avançadas e estruturas de dados.

O Código a seguir, disponível no Quadro 3, carrega recursos de um diretório especificado e os armazena em um conjunto de dados. Ele também cria um mapa de classes que associa cada índice de classe ao nome da classe correspondente. O conjunto de dados é então composto por todas as amostras carregadas, com uma coluna adicional contendo o índice da classe para aquela amostra.

**Quadro 3 – Código de conjunto de dados**

```
def load_features(folder):
    dataset = None
    classmap = {}
    for class_idx, filename in enumerate(glob('%s/*.csv' % folder)):
        class_name = basename(filename)[:4]
        classmap[class_idx] = class_name
        samples = np.loadtxt(filename, dtype=float, delimiter=',')
        labels = np.ones((len(samples), 1)) * class_idx
        samples = np.hstack((samples, labels))
        dataset = samples if dataset is None else np.vstack((dataset, samples))
    return dataset, classmap
```

**Fonte: Eloquent Arduino (2022)**

Em seguida, efetua-se o treinamento com o modelo desejado. O objetivo é que o modelo seja capaz de prever resultados futuros com base nos dados anteriores. O Quadro 4 mostra o treinamento realizado para o algoritmo *Random Forest Classifier*.

**Quadro 4 - Executa treinamento de máquina**

```
features, classmap = load_features('/content')
X, y = features[:, :-1], features[:, -1]
X_train, x_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=7)
classifier = RandomForestClassifier().fit(X_train, y_train)
```

**Fonte: Eloquent Arduino (2022)**

onde:

- `features, classmap = load_features('/content')` = Carrega recursos de um diretório especificado.
- `X, y = features[:, :-1], features[:, -1]`: Esse código separa os recursos de um conjunto de dados em duas variáveis, X e y. X contém todos os recursos menos o último e y contém apenas o último recurso.
- `X_train, x_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=7)` = Divide os dados em dois conjuntos, um para treinamento e outro para teste. X\_train e y\_train são os dados de treinamento, enquanto x\_test e y\_test são os dados de teste. O tamanho do conjunto de testes é especificado como 30% e a treino de 70%.
- `classifier = RandomForestClassifier().fit(X_train, y_train)` = Treina um *Random Forest Classifier* usando os dados de treinamento fornecidos (X\_train e y\_train). Uma vez treinado, o classificador pode ser usado para prever a classe de novos dados.

Do mesmo modo, o respectivo treinamento foi efetuado de forma idêntica para todos os algoritmos citados com a finalidade de obter resultados consistentes. A partir disso, é possível realizar uma análise comparativa entre os modelos, para avaliar qual deles obteve melhores resultados.

### 3.5.3 Métricas de avaliação

A avaliação da performance de um algoritmo de Machine Learning é muito importante para determinar sua eficácia. Existem várias maneiras diferentes de analisar a performance, como *precision*, *recall*, *F1-score*, *accuracy*, área sob a curva ROC, entre outros. Geralmente, é recomendável que o algoritmo do Machine Learning seja avaliado em relação aos dados de treinamento e dados de teste, para que possamos ver como ele se comporta em cenários diferentes.

A avaliação da performance de um algoritmo de ML em um determinado conjunto de dados é realizada por meio da mensuração do quão bem as previsões decorrentes do modelo ajustado reproduzem o valor observado para a resposta de interesse (SANTOS, 2020).

*Accuracy*: É uma medida de quão precisos são os resultados gerados por um algoritmo de aprendizado de máquina. A acurácia é usada para avaliar a performance do modelo e pode ser usada como um indicador da qualidade dos dados fornecidos a ele.

*Precision*: É uma métrica usada para medir a capacidade de um modelo de aprendizagem de máquina em prever corretamente os resultados. Quanto maior o número, melhor o desempenho do modelo.

*Score*: É um valor numérico que indica o desempenho de um modelo de aprendizagem de máquina para prever resultados. O objetivo do score é fornecer aos usuários uma maneira rápida e fácil de avaliar o desempenho do modelo.

*Recall*: É uma medida de desempenho usada para avaliar a capacidade de um modelo preditivo para identificar todos os itens relevantes. É calculado como a proporção entre os itens relevantes identificados corretamente e o total de itens relevantes existentes no conjunto de dados.

Curva AUC: É uma curva usada para visualizar o desempenho de um modelo de classificação binária. É usado para medir a qualidade dos resultados gerados por um modelo de AM.

Para Mariano (2021) uma maneira comum de avaliar o quão bom é o modelo é utilizando a acurácia. A acurácia pode ser considerada uma métrica que apresenta dá uma visão geral do resultado, uma vez que ela avalia os acertos considerando o total de observações.

Pode-se considerar que os níveis de acurácia entre 0% e 30% são baixos e, portanto, há pouca certeza de que os resultados encontrados correspondem aos valores reais. Já em níveis entre 30 e 90% são considerados médios, representando risco moderado de que os resultados não são condizentes com os valores reais (MARIANO, 2021).

Níveis acima de 90 % representam resultados de alta exatidão e baixo risco. “A partir de um nível de 90% de acurácia, os valores encontrados podem ser considerados provados, pois estão menos sujeitos a variações em relação à referência real” (MARIANO, 2021).

## **3.6 Pós-processamento**

### **3.6.1 Algoritmos no microcontrolador**

A biblioteca *MicroMLGen*, disponível para *python*, é uma ferramenta que visa trazer algoritmos de aprendizado de máquina para microcontroladores. Ela gera código em C a partir das ferramentas *scikit-learn* do *Python*.

Devido às restrições de recursos dos dispositivos disponíveis, nem todos os algoritmos são adequados para a elaboração do projeto, restando apenas alguns para desenvolvimento e testes, como por exemplo: `DecisionTreeClassifier`;

DecisionTreeRegressor; Extra TreeClassifier; GaussianNB; LogisticRegression; Linear DiscriminantAnalysis; Linear Regression; Random Forest Classifier; Random Forest Regressor; Support Vector Machines(OneClassSVM) e Support Vector Classifier, sendo esses disponíveis na biblioteca *micromlgen*, que será explicada adiante.

Como resultado do processo, e com o código já em C, o arquivo deve ser colocado na pasta de bibliotecas (*libraries*) do editor de código para arduino, onde deve ser salvo com a extensão *header* (.h). O Quadro 5 mostra o trecho do código onde a biblioteca *micromlgen* converte o código já treinado, para a linguagem C, essencial para o funcionamento do microcontrolador.

**Quadro 5– Código para salvar treinamento em linguagem C**

```
c_code = port(classifier, classmap=classmap)
print(c_code)
```

**Fonte: Eloquent Arduino (2022)**

O Quadro6 apresenta as primeiras linhas do código exportado pela ferramenta para o algoritmo *Random Forest Classifier*, de um total de 9278 presentes no arquivo de cabeçalho.


**Quadro 6– Exemplo de arquivo de cabeçalho Random Forest Classifier**

```
namespace AM {
  namespace Modelo {
    class RandomForestClassifier {
    public:
      /**
       * Predict class for features vector
       */
      int predict(float *x) {
        uint8_t votes[2] = { 0 };
```

**Fonte: Aatoria própria (2023)**

Posteriormente, os arquivos gerados devem ser arquivados em seus respectivos diretórios. A Imagem 10 mostra as pastas onde os arquivos devem ser salvos para a interpretação do editor de código fonte do Arduino.

**Imagem 10– Bibliotecas para arduino**



**Fonte: Autoria própria (2023)**

Uma vez feito, as bibliotecas devem ser importadas para o código fonte junto ao editor de código utilizado, a Imagem11 mostra o procedimento necessário para tal funcionamento.

**Imagem 11– Inclusão das bibliotecas de aprendizagem de máquina**

```
/*Bibliotecas de Aprendizagem de Máquina*/
#include "DecisionTreeClassifier.h"
#include "DecisionTreeRegressor.h"
#include "ExtraTreeClassifier.h"
#include "LogisticRegression.h"
#include "LinearDiscriminantAnalysis.h"
#include "LinearRegression.h"
#include "GaussianNB.h"
#include "OneClassSVM.h"
#include "RandomForestClassifier.h"
#include "RandomForestRegressor.h"
#include "SupportVectorClassifier.h"

ProjetoUTFPR::AM::Modelo::DecisionTreeClassifier DTC_classifier;
ProjetoUTFPR::AM::Modelo::DecisionTreeRegressor DTR_regressor;
ProjetoUTFPR::AM::Modelo::ExtraTreeClassifier ETC_classifier;
ProjetoUTFPR::AM::Modelo::GaussianNB GNB_regression;
ProjetoUTFPR::AM::Modelo::LinearDiscriminantAnalysis LDA_discriminant;
ProjetoUTFPR::AM::Modelo::LinearRegression LR_regression;
ProjetoUTFPR::AM::Modelo::LogisticRegression LogR_regression;
ProjetoUTFPR::AM::Modelo::OneClassSVM ocsvm_classifier;
ProjetoUTFPR::AM::Modelo::RandomForestClassifier RF_classifier;
ProjetoUTFPR::AM::Modelo::RandomForestRegressor RFR_regressor;
ProjetoUTFPR::AM::Modelo::SupportVectorClassifier SVC_classifier;
```

**Fonte: Autoria própria (2023)**

Como criados anteriormente, os *datasets* já processados retornam respostas como “SIM” ou “NÃO”. O Quadro 7, mostra o código necessário para interpretar a resposta, e adiciona uma *flag* 0 ou 1 a variável correspondente para que seja enviada ao banco de dados e dessa forma ser interpretada pela aplicação *web*.

**Quadro 7– Respostas do treinamento de máquina**

```
/*Entrada de dados para os algoritmos*/
floatx_sample[] = {db_Pluv, db_Temp, db_Umid, db_AnenKMH};
```

```
/*Random Forest Classifier*/  
  
if (RF_classifier.predictLabel(x_sample) == "sim" ) {  
    db_RandomForestClassifier = 1;  
}  
if (RF_classifier.predictLabel(x_sample) == "nao" ) {  
    db_RandomForestClassifier = 0;  
}
```

**Fonte: Autoria própria (2023)**

Dessa forma, foram efetuados tais procedimentos com todos os algoritmos disponíveis até então, porém 3 deles apresentaram inconsistência durante o processo de transferência do software ao microcontrolador, foram eles: *Linear Regression*, *LogisticRegression* e *OneClass SVM*, ficando então de fora das avaliações de taxas de acertos referente ao pós-processamento.

É importante ressaltar que a entrada de dados, deve obrigatoriamente estar na ordem apresentada: pluviosidade, temperatura, umidade e velocidade do vento. Caso sejam imputados valores em posições diferentes da ordem estabelecida, os valores podem apresentar discordância. Vale ressaltar que os dados utilizados estão em consonância com o estipulado pela ANDEF (2004) para a aplicação de defensivos agrícolas.

### **3.7 Desenvolvimento da aplicação web**

O sistema foi nomeado como *i-cida*, sendo uma alusão ao sufixo de alguns defensivos agrícolas, e para o desenvolvimento da plataforma, utilizou-se como base, o projeto grátis AdminLTE, disponível gratuitamente na internet. Sua administração é de código aberto e em HTML, podendo ser alterada e adaptada conforme a necessidade requerida. Dessa forma, mudanças significativas na aparência foram efetuadas, e campos adicionais foram customizados, como descritos a seguir.

#### **3.7.1 Manipulação do banco de dados**

Para a manipulação e gerenciamento do Banco de Dados é necessário a utilização de um Sistema Gerenciador de Banco de Dados (SGBD). O gerenciamento de banco de dados é o processo de organizar e armazenar dados em um banco de dados. Isso envolve criar estruturas para armazenar dados, definir regras para garantir que os dados sejam consistentes e precisos, criar mecanismos para recuperar e armazenar informações, bem como controlar o acesso a esses dados. O gerenciamento de banco de dados também inclui monitorar o desempenho do banco de dados e realizar manutenção preventiva.

### 3.7.1.1 Ferramenta MySql

MySQL é um sistema de gerenciamento de banco de dados relacional que utiliza a linguagem de consulta SQL. É um dos sistemas de gerenciamento de banco de dados mais utilizados no mundo, sendo usado em muitas aplicações web e empresariais.

“Existem várias razões para utilizar o MySQL, dentre elas se destacam a robustez e desempenho deste SGBD, além da facilidade de instalação, configuração e uso” (DUARTE, 2008).

Dessa forma, MySQL tornou-se uma excelente opção para o desenvolvimento da aplicação *web*. Além de sua facilidade, apresenta um alto desempenho e recursos robustos para os dados enviados. A Imagem 12 apresenta as colunas nas quais os dados da estação são arquivados.



**Imagem 12– Colunas do banco de dados**

#	Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Predefinido	Comentários	Extra	Acções
<input type="checkbox"/>	1 ID	int(16)			Não	Nenhum		AUTO_INCREMENT	Muda  Elimina  Mais
<input type="checkbox"/>	2 Data	timestamp		on update CURRENT_TIMESTAMP	Não	CURRENT_TIMESTAMP		ON UPDATE CURRENT_TIMESTAMP	Muda  Elimina  Mais
<input type="checkbox"/>	3 Temp	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	4 Umid	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	5 PresAtm	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	6 SenTermica	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	7 PontOrvalho	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	8 PluvAcum	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	9 VelVento	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	10 DirVento	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	11 FormNuvens	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	12 UmidSolo	float			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	13 DecisionTreeClassifier	int(11)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	14 DecisionTreeRegressor	int(11)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	15 ExtraTreeClassifier	int(11)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	16 GaussianNB	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	17 LinearRegressor	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	18 LogisticRegression	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	19 OneClassSVM	int(11)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	20 RandomForestClassifier	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	21 RandomForestRegressor	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	22 SupportVectorMachines	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	23 PrevTemp	int(2)			Não	Nenhum			Muda  Elimina  Mais
<input type="checkbox"/>	24 LinearDiscriminantAnalysis	int(11)			Não	Nenhum			Muda  Elimina  Mais

Fonte: Autoria própria (2023)

Como visto, foram criadas um total de 24 colunas, podendo ser alteradas, excluídas, atualizadas ou criadas novas colunas, para novos itens a qualquer momento, sem esforços significativos. Os dados podem ser exportados posteriormente no formato CSV, facilitando futuras análises e comparativos dos dados coletados.

Dessa forma, os dados recebidos são as *flags* criadas anteriormente no microcontrolador, 0 e 1, ficando sob responsabilidade da aplicação *web* interpreta-las e responder se deve ou não ser efetuada a aplicação de defensivos agrícolas. A Imagem 13 mostra os dados brutos inseridos no banco de dados.

**Imagem 13– Dados brutos sendo colocados ao banco de dados**

DecisionTreeClassifier	DecisionTreeRegressor	ExtraTreeClassifier	GaussianNB	LinearRegressor	LogisticRegression	OneClassSVM	RandomForestClassifier	RandomForestRegressor	SupportVectorClassifier
1	1	1	1	0	0	0	1	1	0
0	0	0	1	0	0	0	0	0	0
1	1	1	1	0	0	0	1	1	0
0	0	0	1	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0
1	1	1	1	0	0	0	1	1	0
0	0	1	1	0	0	0	0	0	0
1	1	1	1	0	0	0	1	1	0
0	0	0	1	0	0	0	0	0	0
1	1	1	1	0	0	0	1	1	0
0	0	0	1	0	0	0	0	0	0
0	0	1	1	0	0	0	0	0	0

Fonte: Autoria própria (2023)

### 3.7.2 Conexão do sistema com o banco de dados

PHP é uma linguagem de programação *open source* muito popular, especialmente adequada para o desenvolvimento *web* e que pode ser embutida em HTML. Dessa forma, foi utilizado tal linguagem para efetuar as conexões com o banco de dados, e transformar cada leituras efetuadas em informações mensuráveis para cada item disponível no *Dashboard* do sistema.

O Quadro 8 mostra o exemplo de código, onde o acesso ao banco de dados é efetuado, acessado, e convertida a leitura para informação de fácil interpretação pelo usuário de “SIM” ou “1” para pulverização e “NAO” ou “0” para a nao pulverização a cada 5 segundos. Caso nenhum dos valores sejam interpretados, a mensagem “ERROR!” será exibida.

**Quadro 8– Código PHP para consultas ao banco de dados**

```
<?php
header("Refresh:5");
define ('HOST', '*****');
define ('USUARIO', '*****');
define ('SENHA', '*****');
define ('DB', '*****');

$cx = mysqli_connect(HOST, USUARIO, SENHA, DB) or die ('NÃO FOI POSSÍVEL
CONECTAR');

//selecionando o banco de dados
$db = mysqli_select_db($cx);

//criando a query de consulta à tabela criada
$sql = mysqli_query($cx, "SELECT RandomForestClassifier FROM DADOS ORDER BY id
DESC") or die(mysqli_error($cx));

//Lendo o último registro do banco de dados
$row = $sql->fetch_assoc();
$RandomForestClassifier = $row[RandomForestClassifier];

if($RandomForestClassifier == 1){
    $pulverizacao = "SIM";
    echo "<b><font color='#FFFFFF' font size='5' style='text-align: left;'>
    $pulverizacao</font></b>";
}

if($RandomForestClassifier == 0){
    $pulverizacao = "NÃO";
    echo "<b><font color='#FFFFFF' font size='5' style='text-align: left;'>
    $pulverizacao</font></b>";
}
```

```
}  
if($RandomForestClassifier>1 or $RandomForestClassifier<0){  
  $pulverizacao = "ERROR!";  
  echo "<b><font color='#FFFFFF' font size='5' style='text-align: left;'>  
$pulverizacao</font></b>";  
}  
?>
```

**Fonte: A autoria própria (2023)**

## 4 RESULTADOS E DISCUSSÕES

### 4.1 Montagem da estação

Para o manuseio e alocação da estação no ambiente, foi colocado um suporte para todos os sensores, uma caixa hermética para a proteção o microcontrolador e do repetidor WI-FI e uma segunda caixa hermética, próxima ao solo, para armazenamento das fontes de energia e conexões elétricas. A Fotografia 4 mostra a estação desenvolvida montada e disposta para efetuar medições.

Fotografia 4 - Estação meteorológica desenvolvida

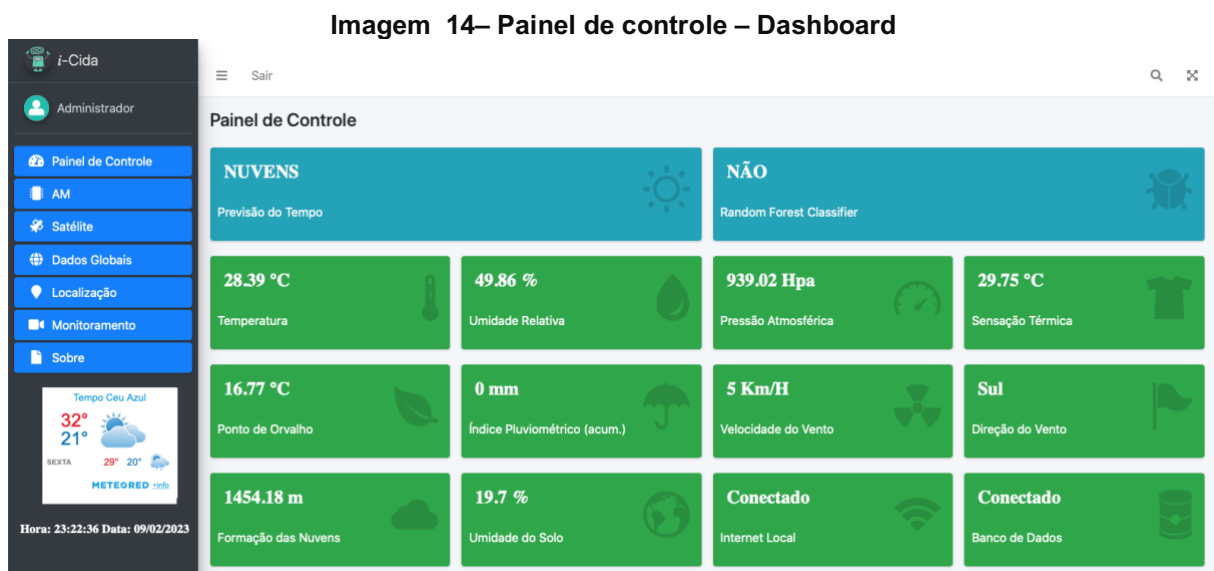


Fonte: Autoria própria (2023)

## 4.2 Aplicação web

### 4.2.1 Dashboard

No painel de controle desenvolvido, as informações dispostas, incluem a temperatura, umidade relativa, pressão atmosférica, sensação térmica, índice pluviométrico, velocidade do vento, direção do vento, altura de formação da base das nuvens e umidade do solo. Apresenta também o status da internet em que está instalada a estação e o status da conexão com o banco de dados. Na Imagem 14 é apresentado a estrutura do painel de controle do sistema.



Fonte: Autoria própria (2023)

### 4.2.2 Painel aprendizagem de máquina

A análise do painel apresentado é bastante simplista, mostra apenas a resposta “SIM” ou “NÃO” para a execução da atividade de aplicação de defensivos agrícolas. Cada algoritmo utilizado está identificado com seu respectivo nome e sua resposta. O painel de aprendizagem de máquina é usado para analisar os dados e gerar *insights* sobre o melhor momento para efetuar a aplicação de defensivos, como melhorar o desempenho dos algoritmos. Além disso, também pode ser usado para

testar novos algoritmos e comparar seus resultados com os dos algoritmos já existentes. Assim, o painel permite ao usuário obter informações úteis sobre o desempenho dos algoritmos em diferentes cenários.

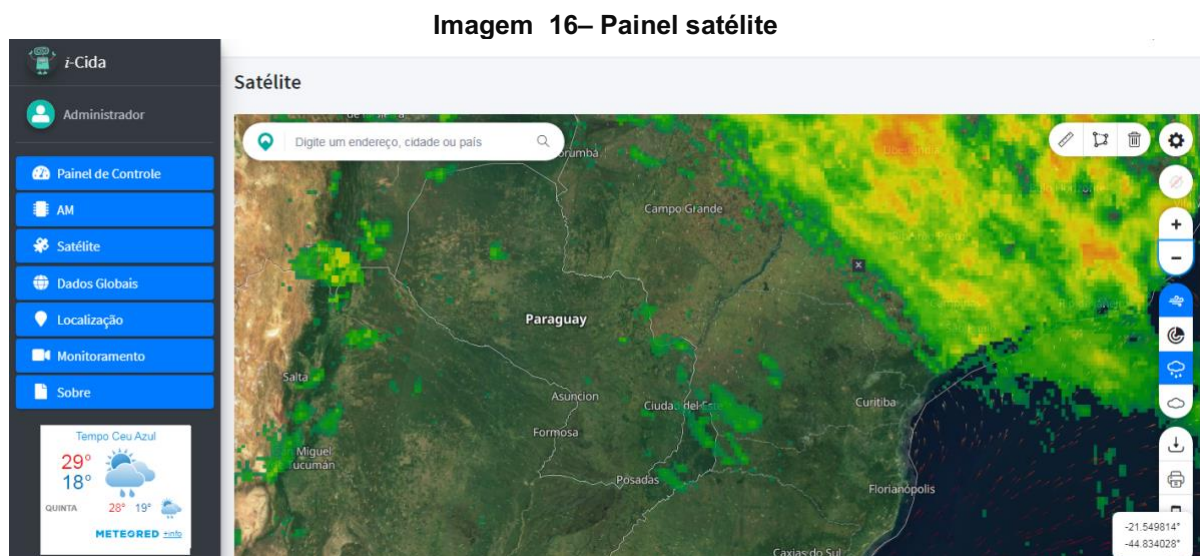
A Imagem 15 mostra a tela com os resultados provenientes dos algoritmos de aprendizagem de máquina, já processados e arquivados no banco de dados.



Fonte: Autoria própria (2023)

#### 4.2.3 Painel satélite

Informações proveniente de satélites disponibilizados pela plataforma Gosur permitiram exibir informações sobre precipitação pluviométrica, movimentação de nuvens e direção do vento. A Imagem 16 mostra dos dados disponibilizados.

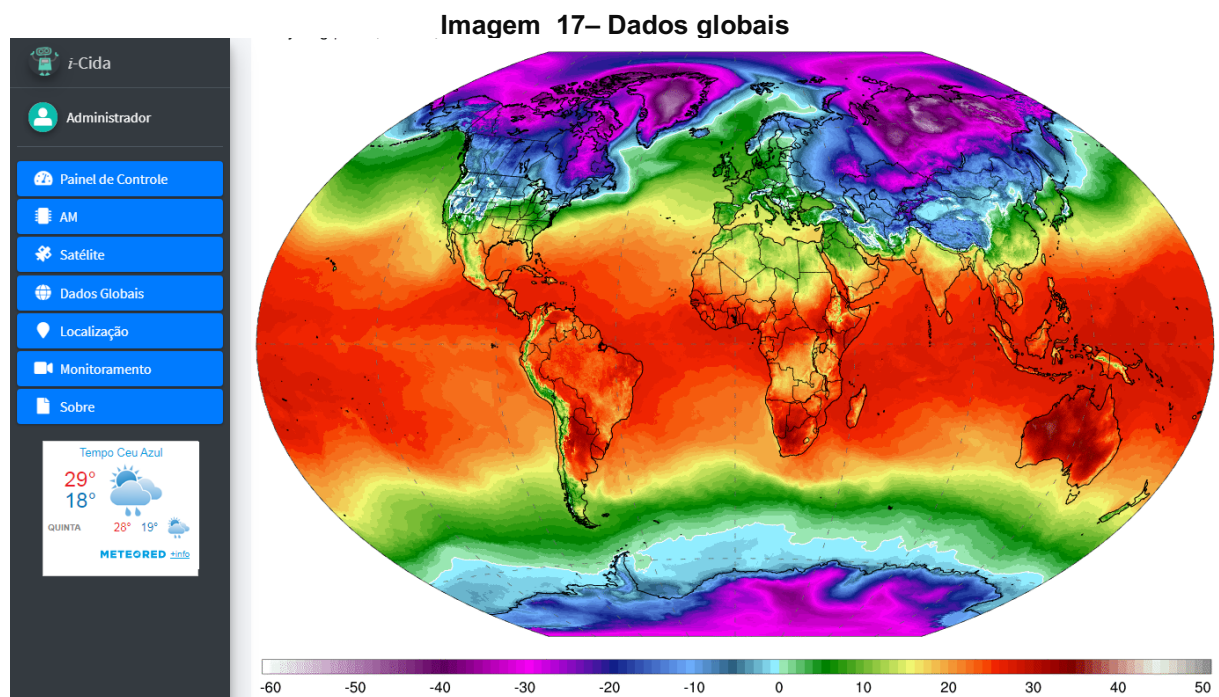


Fonte: Gosur (2023)

#### 4.2.4 Painel dados globais

Condições climáticas globais são essenciais para o entendimento dos fenômenos climáticos mundiais. Para acesso a essas informações, e eventuais comparativos de previsões, utilizou-se os dados do site *ClimateReanalyzer*, que consistem em uma plataforma para visualização de dados climáticos e meteorológicos. Esta plataforma utiliza informações climáticas usando dados dos registros históricos e interfaces de análise.

Desse modo, para as consultas específicas foram utilizados os dados de temperatura, precipitação e ventos, sendo essas atualizadas diariamente, assim como também estão presentes previsões para o clima global até 2100. A Imagem 17 mostra a tela contendo os dados globais, e as previsões anteriormente exemplificadas.



Fonte: ClimateReanalyzer (2023)

#### 4.2.5 Painel localização

Um painel de localização geográfica é uma ferramenta de visualização que permite aos usuários ver, analisar e interagir com dados geográficos. Os painéis de



localização geográfica geralmente incluem elementos como mapas, gráficos e tabelas que exibem informações sobre uma área específica.

Portanto, foi implantado um painel de localização não só demonstrando a localização da propriedade parceira, mas também sendo utilizado para possíveis análises quanto ao relevo e suas alterações ao clima local. A Imagem 18 mostra a localização da propriedade parceira.



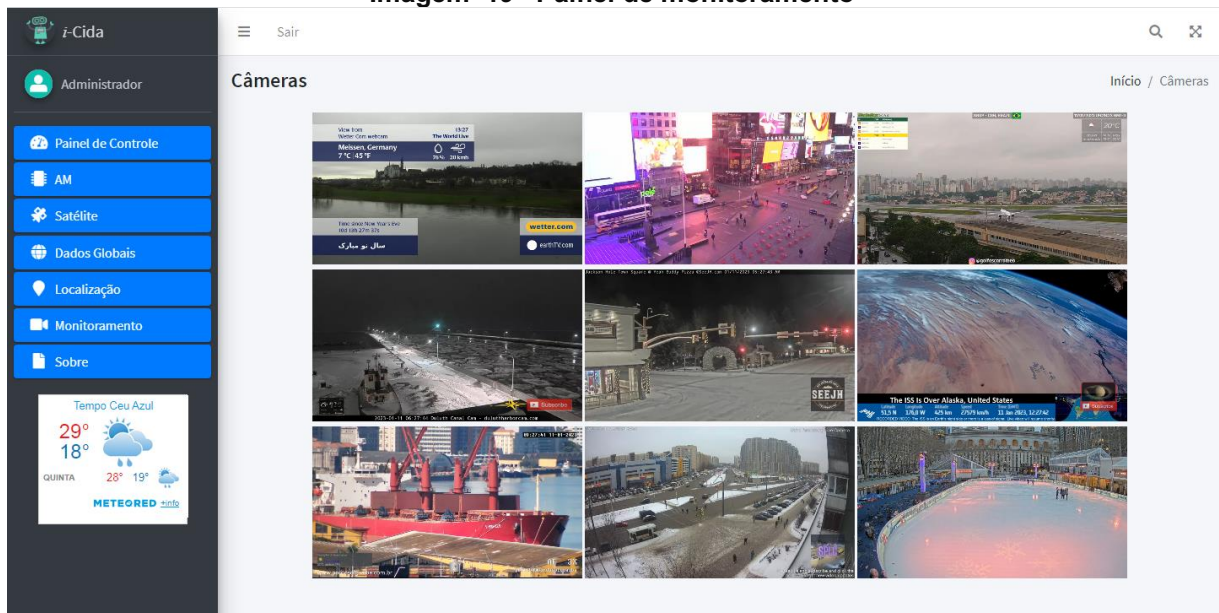
Fonte: Google Maps (2023)

#### 4.2.6 Painel monitoramento

Um painel de monitoramento permite aos usuários monitorar e gerenciar seus recursos de forma mais eficiente. O painel de monitoramento foi adicionado para fins de exemplificação da possibilidade de desenvolvimento de ferramentas onde possam ser utilizadas câmeras para monitoramento das atividades agrícolas na propriedade.



Imagem 19– Painel de monitoramento



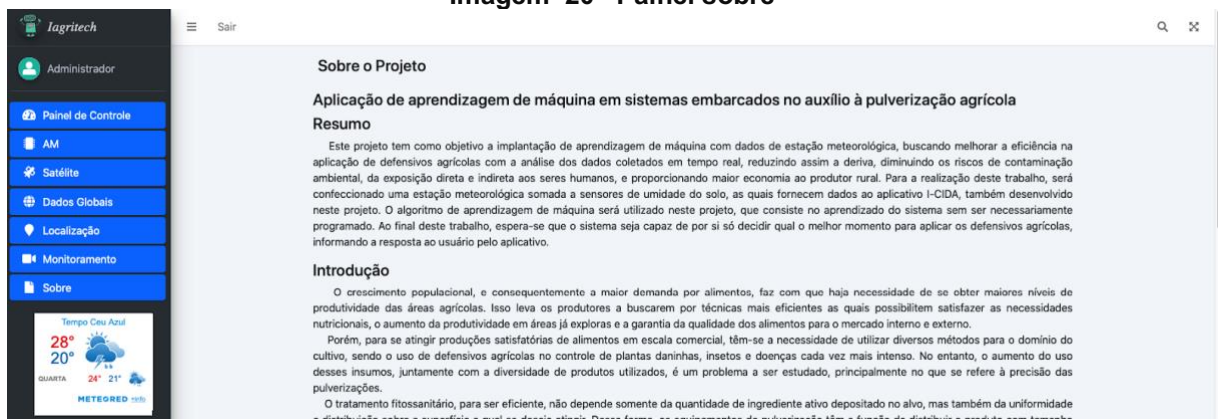
Fonte: Autoria própria (2023)

#### 4.2.7 Painel sobre

Um painel de informações é um conjunto de dados organizados que são exibidos em um formato visual, como gráficos, tabelas ou diagramas. Os painéis de informação são usados para fornecer uma visão geral rápida e precisa de dados específicos mostrados.

Neste trabalho, foi adicionado para apresentar o andamento das pesquisas e informações relevantes para o trabalho. A Imagem 20 mostra como o item é demonstrado.

Imagem 20– Painel sobre



Fonte: Autoria própria (2023)

### 4.3 Resultados das métricas de avaliação

Após a execução do algoritmo de aprendizagem de máquina, as métricas de avaliação foram apresentadas para cada qual desenvolvido. A Tabela 1 mostra os resultados das métricas de avaliação calculadas utilizando *oscikit-learn*.

**Tabela 1– Resultados das métricas de avaliação**

<b>Modelo</b>	<b>Accuracy (%)</b>	<b>Precision (%)</b>	<b>F1 Score (%)</b>	<b>Recall (%)</b>	<b>AUC (%)</b>
DecisionTreeClassifier	99,96	99,91	99,96	100,00	99,96
DecisionTreeRegressor	99,96	99,91	99,96	100,00	99,96
Extra TreeClassifier	96,25	97,96	96,08	94,27	96,20
Gaussian NB	61,25	100,00	33,95	20,44	60,22
Linear DiscriminantAnalysis	69,79	69,41	68,66	67,92	69,74
Linear Regression	73,67	74,12	72,30	70,57	73,59
LogisticRegression	74,25	71,66	74,71	78,03	74,34
Random Forest Classifier	99,96	99,91	99,96	100,00	99,96
Random Forest Regressor	99,96	99,91	99,96	100,00	99,96
Support Vector Classifier	75,67	79,22	73,09	67,84	75,47
OneClass SVM	11,96	74,12	72,30	70,57	24,18

**Fonte: Autoria própria (2023)**

### 4.4 Taxas de acertos

Nos últimos anos inúmeros algoritmos de aprendizado de máquina foram desenvolvidos visando resolver problemas nos mais diferentes âmbitos, tornando-se crucial comparar pelo menos algumas dessas ferramentas para escolher aquela que produz um modelo com o melhor desempenho preditivo. Isso ocorre porque nenhum algoritmo é superior a todos os outros em todos os conjuntos de dados possíveis; ao contrário, um determinado algoritmo pode funcionar melhor em um determinado conjunto de dados, mas não necessariamente produzir os resultados mais satisfatórios (JAMES et al., 2014).

Os dados analisados correspondem a 6281 leituras válidas, coletadas em locais distintos, e em condições climáticas igualmente distintas, maximizando a generalização dos modelos, e abrangendo-os nas mais diversas situações para as predições, sendo 6076 leituras coletadas em laboratório e 206 leituras na propriedade parceira.

As coletas foram efetuadas nos dias 19/02/2023, 20/02/2023 e 22/02/2023. A Tabela 2 mostra os dados de temperatura, umidade, velocidade do vento e pluviosidade máximos e mínimos disponíveis em campo no período da coleta.

<b>Leituras</b>	<b>Máximo</b>	<b>Mínimo</b>	<b>Média</b>
Temperatura (°C)	26	21	22,1
Umidade (%)	83	58	75,4
Vento (Km/h)	14	0	7,0
Pluviosidade (mm)	0	0	0

**Fonte: Autoria própria (2023)**

As tabelas mostram as taxas de acertos, levando em consideração às informações propostas pela ANDEF (2004). A Tabela 3 mostra os resultados obtidos em laboratório, efetuadas nos dias 19/02/2023 e 20/02/2023, totalizando 6075 leituras. Os testes em laboratório são fundamentais, pois apresentam condições climáticas adversas as apresentadas no meio ambiente, como por exemplo, alteração de temperatura em ambiente fechado e diferenças consideráveis na velocidade do ventos.

Contudo, três algoritmos não foram testados nos experimentos, pois apresentaram inconsistência na transferência do algoritmo ao microcontrolador, sendo eles: *Linear Regression*, *LogisticRegression* e *OneClass SVM*. Portanto, não apresentando dados para análises. Nesse caso, o banco de dados por padrão armazena a *flag 0*.

<b>Modelos</b>	<b>Acertos</b>	<b>Erros</b>	<b>Taxa de Acertos (%)</b>	<b>Taxa de Erros (%)</b>
DecisionTreeClassifier	5279	796	86,8	13,2
DecisionTreeRegressor	5279	796	86,8	13,2

Extra TreeClassifier	5827	248	95,9	4,1
Gaussian NB	3218	2857	52,9	47,1
Linear DiscriminantAnalysis	2857	3218	47,0	53,0
Linear Regression	x	x	x	x
LogisticRegression	x	x	x	x
Random Forest Classifier	5279	796	86,8	13,2
Random Forest Regressor	5279	796	86,8	13,2
Support Vector Classifier	2857	3218	47,0	53,0
OneClass SVM	x	x	x	x

Fonte: Aatoria própria (2023)

Para simular a taxa de acertos em uma propriedade rural, foi realizado um ensaio com 206 coletas efetuadas no dia 22/02/2023 no período matutino, no local disponibilizado pelo proprietário na propriedade parceira. Os resultados demonstram que a maioria dos modelos apresentam taxas de acertos altas, com destaque para o modelo *Extra TreeClassifier* com 95,9% de acertos (Tabela 4).

A taxa de erros refere-se à incapacidade dos algoritmos em prever o momento da aplicação de defensivos agrícola, quando comperado com as informações da ANDEF(2004). Portanto, ocorre o erro na resposta, salvando-a no banco de dados, e consequentemente, apresentado resposta errônea na aplicação *web*.

**Tabela 4 - Taxa de acertos na propriedade**

<b>Modelos</b>	<b>Acertos</b>	<b>Erros</b>	<b>Taxa de Acertos (%)</b>	<b>Taxa de Erros (%)</b>
DecisionTreeClassifier	179	27	86,8	13,2
DecisionTreeRegressor	179	27	86,8	13,2
Extra TreeClassifier	195	195	95,6	4,4
Gaussian NB	107	99	51,9	48,1
Linear DiscriminantAnalysis	100	106	48,5	51,5
Linear Regression	x	x	x	x
LogisticRegression	x	x	x	x

Random Forest Classifier	179	27	86,8	13,4
Random Forest Regressor	179	27	86,8	13,4
Support Vector Classifier	100	106	48,5	51,5
OneClass SVM	x	x	x	x

Fonte: Autoria própria (2023)

Dessa forma, é possível observar que os algoritmos mesmo em condições climáticas distintas, apresentaram taxas de acertos similares em ambos os ambientes, aumentando assim o grau confiabilidade dos algoritmos, pois executa as funções especificadas com um comportamento consistente (BARCELLOS, 2018). Já a Tabela 5 mostra os resultados gerais obtidos, onde são levadas em consideração todas as amostras coletadas no período descrito.

Tabela 5 - Taxas de acerto total

Modelos	Acertos	Erros	Taxa de Acertos (%)	Taxa de Erros (%)
DecisionTreeClassifier	5458	823	86,8	13,2
DecisionTreeRegressor	5458	823	86,8	13,2
Extra TreeClassifier	6022	259	95,9	4,21
Gaussian NB	3325	2956	52,9	47,1
Linear DiscriminantAnalysis	2957	3324	47,0	53,0
Linear Regression	x	x	x	x
LogisticRegression	x	x	x	x
Random Forest Classifier	5458	823	86,8	13,2
Random Forest Regressor	5458	823	86,8	13,2
Support Vector Classifier	2957	3324	47,0	53,3
OneClass SVM	x	x	x	x

Fonte: Autoria própria (2023)

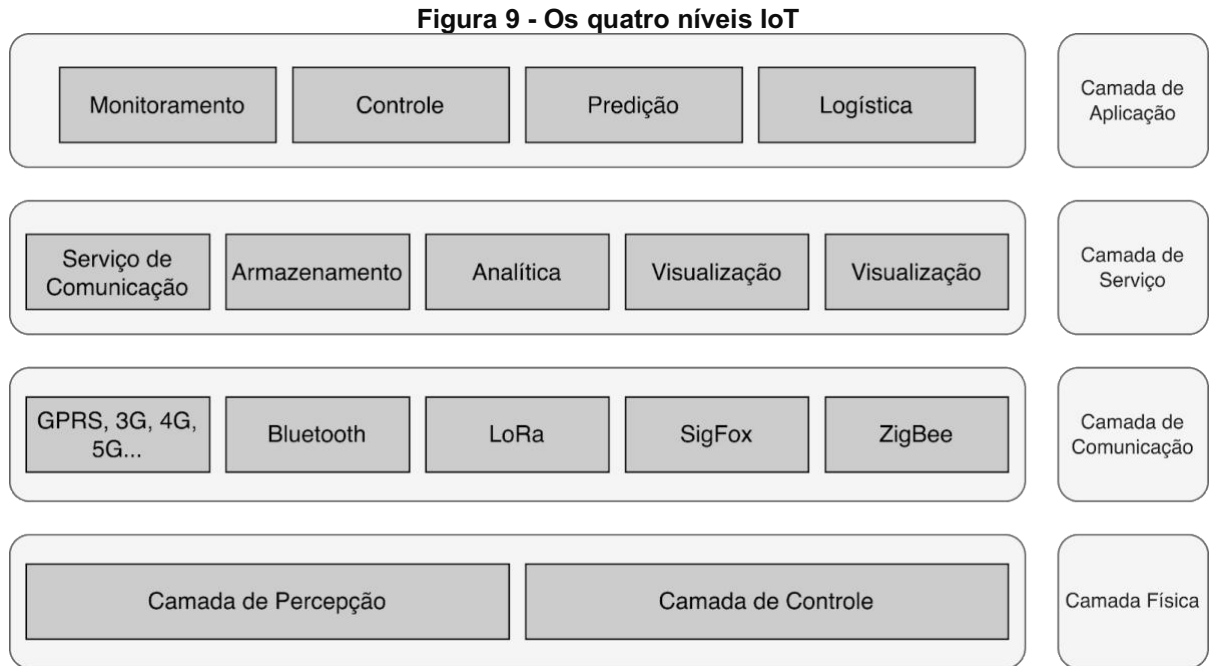
Como mostrado na Tabela 5, o algoritmo com maior taxa de acertos foi o *Extra TreeClassifier*, acertando cerca de 95.9% das leituras válidas, valor muito próximo aos do treinamento do modelo disponível na Tabela 1, isso corresponde a aproximadamente 48% acertos a mais que os que obtiveram o pior desempenho, que são o *Linear DiscriminantAnalysis* e *Support Vector Classifier*. Nota-se também o alto índice de acerto dos algoritmos *DecisionTreeClassifier*, *DecisionTreeRegressor*, *Random Forest Classifier* e *Random Forest Regressor*, apresentando acertos superiores a 85%.

Percebe-se também uma alta taxa de linearidade nos modelos, quanto aos diferentes ambientes. Variações não superiores a 2% nas taxas de acertos, fazem com que os modelos apresentem um grau relevante de confiabilidade, no que tange a uma pequena escala de processamento de dados.

Bons modelos de aprendizagem de máquina devem evitar *underfitting* e *overfitting*. *Overfitting* ocorre quando, nos dados de treino, o modelo apresenta um bom desempenho, porém quando em teste o modelo é ruim. Já no *underfitting*, o desempenho do modelo já apresenta discrepância no próprio treinamento. O modelo não encontrar relações entre os dados e o teste comumente não ocorre, pois é previamente descartado (ABRACD, 2020).

Desse modo, nota-se também, a existência de *overfitting* nos modelos que tiveram desempenho nos testes inferior as métricas. Entende-se que o modelo aprendeu tão bem as relações existentes entre as variáveis, que acabou apenas repetindo, e ao receber as informações das variáveis preditoras, o modelo tenta aplicar as mesmas regras, porém com dados diferentes esta regra não tem validade, e o desempenho é drasticamente afetado. Em geral, para resolver tal problema, utiliza-se o aumento do volume dos dados de treinamento e teste, como por exemplo 80% para treino 20% para testes.

Quanto ao IoT (*Internet of Things*), termo usado para descrever a conexão de dispositivos eletrônicos com a internet, cuja qual, permite que os dispositivos se comuniquem entre si e troquem dados sem intervenção humana. Os níveis de IoT são categorias que ajudam a descrever os diferentes tipos de IoT disponíveis. A Figura 9 mostra os 4 níveis da IoT descritos por Talavera et al. (2017).



Fonte: Adaptado de TALAVERA et al. (2017).

A camada física é a camada mais básica da Internet das Coisas. É responsável por garantir que os dispositivos se conectem à rede, seja por meio de Wi-Fi, Bluetooth, Zigbee ou outras tecnologias de comunicação sem fio. Dessa forma, a utilização da rede WI-FI estabelecida da propriedade rural contempla a camada física dos dispositivos IoT, pois além de possuir uma grande abrangência na localidade, proporciona a facilidade de acesso aos usuários e dispositivos à rede.

Já a camada de comunicação, é responsável por coletar, armazenar e processar os dados gerados pelos dispositivos conectados à rede. Portanto, a utilização da estação meteorológica em questão abrange tal nível, uma vez que, conectada a rede, coleta, processa e envia dados em tempo real para um banco de dados, que os armazena por tempo indeterminado.

Quanto a camada de serviço, cuja responsabilidade é analisar os dados coletados e gerar informações úteis para tomadas de decisão e ações futuras, também se encontra abrangida, uma vez que os algoritmos de aprendizagem de máquina no microcontrolador geram informações uteis e interpretáveis para os usuários, afim de auxiliá-los nas tomadas de decisões. Os algoritmos de aprendizado de máquina são usados neste nível para descobrir padrões nos dados e gerar *insights*.

Por fim, a camada de aplicação que é responsável por representar aplicações que para que usuários finais interajam com os dispositivos conectados à rede, também

é contemplada, uma vez que a aplicação *web i-Cida* permite ao usuário acessar os dados em tempo real, que além de fácil utilização, apresenta respostas objetivas e de fácil interpretação para o auxílio à aplicação de defensivos agrícolas.



## 5 CONCLUSÃO

A estação meteorológica desenvolvida, coletando dando em tempo real e utilizando aprendizagem de máquina melhora a tomada de decisão quanto à aplicação de defensivos agrícolas, mostra respostas objetivas quanto ao melhor momento para efetuar a aplicação, diminuindo assim riscos de deriva.

Quanto ao aprendizado de máquina destacam-se o algoritmo *Extra TreeClassifier* com taxa de acerto de 95%, seguido do *DecisionTreeClassifier*, *DecisionTreeRegressor*, *Random Forest Classifier* e *Random Forest Regressor* com taxas próximas a 85% são os mais eficientes.

A aplicação *i-cida*, demonstra facilidade na visualização dos dados coletados e processados, mostrando a resposta ao usuário se o momento atual é ideal para a pulverização agrícola, e ainda adiciona diversos recursos para complementar a análise dos dados, como dados globais, imagens de satélite. etc.

### 5.1 Sugestões de trabalhos futuros

Durante a pesquisa, constatou-se a necessidade de um aprofundamento técnico em alguns itens relacionados, pois possuem uma ampla gama de possibilidades que agregam conhecimento a pesquisa. Portanto, recomenda-se como trabalhos futuros os pontos destacados a seguir.

Como por exemplo, o aprofundamento na distribuição do WI-FI em grandes áreas. Isso poderá gerar novas possibilidades, pois com uma ampla cobertura de sinal, é possível o surgimento de novos equipamentos e novas tecnologias, seja para uso pessoal, como monitoramento da propriedade, *notebooks* e *tablets*, ou para aumento de produtividade como monitoramento e acompanhamento da produção agrícola, etc.

Quanto a estação meteorológica, nota-se a relevância em sua continua pesquisa. A melhoria do sistema embarcado (*software* e *hardware*), aadição de novos sensores, de um melhor software no microcontrolador, resulta em melhor coleta de dados e contribui para o armazenamento das informações em um *datalogger* com maior exatidão, com menor consumo de energia e redução do tamanho da mesma.

Também se nota a necessidade de maiores estudos quanto aos algoritmos utilizados, e qual o melhor modelo a ser implantado. Diferentes algoritmos podem apresentar diferentes resultados, por isso, o amplo estudo dos mesmos, juntamente com novas análises e testes apresentam-se como necessárias à melhoria das pesquisas na área.

Métricas de avaliações como RMSE(*Root Mean Squared Error*), também se apresentam como possíveis objetos de estudos para algoritmos de regressão em trabalhos futuros.

Já as aplicações *web* necessitam de constante dinamismo em seu desenvolvimento. Portanto, o estudo contínuo torna-se necessário, buscando novos métodos de apresentação dos dados e processamento das leituras efetuadas junto ao banco de dados. Assim como a possível adição de aprendizado de máquina direto à plataforma, diminuindo assim a carga de processamento do microcontrolador, e processando os modelos direto ao servidor.

Por fim, vale ressaltar que, visando a melhoria contínua do desenvolvimento do projeto, todos os códigos estão disponíveis no diretório github para consulta e análise, sendo possível seu acesso e reutilização dos mesmos.

## REFERÊNCIAS

- ABRACD - ASSOCIAÇÃO BRASILEIRA DE CIÊNCIA DE DADOS. Disponível em: <https://abracd.org/overfitting-e-underfitting-em-machine-learning/>. Acesso em: 12 fev. 2023.
- AHMED, N.; RAHMAN, H.; HUSSAIN, Md I. **A comparison of 802.11ah and 802.15.4 for IoT**. Ict Express, v. 2, n. 3, p. 100102, 2016. Acesso em: 14 nov. 2021.
- AKENSON, N. B.; YATES, W. E. **Pesticide application equipment and techniques**. Roma: FAO, 1979. 257 p. (FAO Agricultural Services Bulletin). Acesso em: 22 out. 2021.
- ANDEF - Associação Nacional de Defesa Vegetal. **Manual de tecnologia de aplicação de produtos fitossanitários**. Campinas: LineaCreativa, 2004. 52 p. Acesso em: 21 out. 2021.
- AROCA, R. V. **Análise de sistemas operacionais de tempo real para aplicações de robótica e automação**. Orientador: Prof. Dr. Glauco Augusto de Paula Caurin. 2008. 154 p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos da Universidade de São Paulo, 2008. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18149/tde-09012009-210323/publico/DissertacaoArocaMestrado2008.pdf>. Acesso em: 12 dez. 2022.
- ARTIFICIAL intelligence in agriculture market by technology (machine learning, computer vision, and predictive analysis), offering (software, hardware, al-as-a-service, and services), application, and geography - global forecast to 2026**. [S. l.], 2019. Disponível em: AI in Agriculture Market by Technology, Offering, Application | COVID-19 Impact Analysis | MarketsandMarkets. Disponível em: <https://www.marketsandmarkets.com/Market-Reports/ai-in-agriculture-market-159957009.html>. Acesso em: 30 jan. 2023.
- AYOADE, J. O. **Introdução à climatologia para os trópicos**. 11. ed. Rio de Janeiro: Bertrand Brasil, 2006. Acesso em: 20 out. 2021.
- BANZI, M.; SHILOH, M. **Primeiros passos com o arduino – 2a Edição**. [s.l.] Novatec Editora, 2015. Acesso em: 10 ago. 2021.
- BARCELLOS, L.C. CARVALHO, Y.C.; SILVA, A.L. **Estudo sobre a penetração de gotas de pulverização no dossel da cultura da soja [*Glycinemax* (L.) Merrill]**. Engenharia na Agricultura, Viçosa, MG, v. 6, n. 2, p.81-94, 1998. Acesso em: 21 out. 2021.
- BARCELLOS, M. **Engenharia de software**. [s.l.: s.n.]. Disponível em: <https://nemo.inf.ufes.br/wp-content/uploads/Monalessa/EngSoftware/NotasDeAula-EngSw-EngComp-v2018.pdf>. Acesso em: 24 set. 2022.
- BERGER, A. S. **Embedded systems design: an introduction to processes, tools, and techniques**. [s.l.: s.n.]. CMP Books, 2002. Disponível em: <http://dsp-book.narod.ru/ESDIPTT.pdf>. Acesso em: 15 Dez. 2022.

BOHMONT, B.L. **The new pesticide user's guide**. Fort Collins: B. & K. Enterprises, 1981. 402 p. Acesso em: 16 dez. 2022.

BOLFE, E. L.; MATIAS, L. F.; FERREIRA, M. C. **Sistemas de informação geográfica: Uma Abordagem Contextualizada na História**. Geografia, v. 33, n. 1, p. 69–88, 16 out. 2008. Acesso em: 11 fev. 2023.

BORGES, A. et al. **Desenvolvimento de um dashboard para apresentação de dados relacionados à evasão no IFSC Lages SC**. 2020. Disponível em: [https://repositorio.ifsc.edu.br/bitstream/handle/123456789/2451/Amarildo\\_M\\_Borges%3BVin%C3%ADcius\\_Waltrick\\_TCCGRAD\\_2020.pdf?sequence=1&isAllowed=y](https://repositorio.ifsc.edu.br/bitstream/handle/123456789/2451/Amarildo_M_Borges%3BVin%C3%ADcius_Waltrick_TCCGRAD_2020.pdf?sequence=1&isAllowed=y). Acesso em: 10 fev. 2023.

BREIMAN, L. **Stacked regressions**. *machine learning*, v. 24, n. 1, p. 49–64, 1996. Acesso em: 18 set. 2021.

BURT, S. **The weather observer's handbook**. Cambridge University Press, New York, 2012. Acesso em: 15 jul. 2021.

BUTTAZZO, G. **Research trends in real-time computing for embedded systems**. ACM SIGBED Review, v. 3, n. 3, p. 1–10, jul. 2006. Acesso em: 25 mar. 2022.

CAMPAGNOLO, L. **Cuidados na pulverização agrícola**. In: Cuidados na pulverização agrícola. Acesso em: 28 mai. 2021.

CARVALHO, A. C. P. L. F. et al. **Inteligência artificial - uma abordagem de aprendizado de máquina. 2ª edição**. ed. [S. l.: s. n.], 2021. ISBN 8521637349. Acesso em: 5 out. 2022.

CARVALHO, B. R. et al. **Drone para pulverização agrícola e de inseticidas**. repositorio.uniube.br, 2019. Acesso em: 10 fev. 2023.

CARVALHO, J. P. et al. **Investigação de desempenho de ligações ponto-a-ponto IEEE 802.11 AC**. 2022. 8º Ciclo de Conferências da Faculdade de Ciências da Universidade da Beira Interior-Escola e Universidade. Acesso em: 6 fev. 2023.

CARNEIRO, L. V. et al. **Avaliação do método naivebayes gaussiana na classificação de amostras da base de dados breasttissue**. VI Congresso Nacional de Pesquisa e Ciência e Ensino, [s. l.], 2021. Disponível em: [https://www.editorarealize.com.br/editora/anais/conapesc/2021/TRABALHO\\_EV161\\_MD1\\_SA105\\_ID2111\\_22092021170519.pdf](https://www.editorarealize.com.br/editora/anais/conapesc/2021/TRABALHO_EV161_MD1_SA105_ID2111_22092021170519.pdf). Acesso em: 15 fev. 2023.

CAVALCANTE, S; BARROS, E. **Introdução aos sistemas embarcados**. Universidade Federal de Pernambuco – UFPE, 2020. Disponível em: <https://www.cin.ufpe.br/~vba/periodos/8th/s.e/aulas/STP%20-%20Intro%20Sist%20Embarcados.pdf>. Acesso em: 20 abr. 2022.

CERRI, R; CARVALHO, A.C.P.L.F. **Aprendizado de máquina: breve introdução e aplicações**. Cadernos de Ciência e Tecnologia, v. 34, n. 3, p. 297-313, 2017 Tradução. Disponível em: <https://seer.sct.embrapa.br/index.php/cct/article/view/26381>. Acesso em: 14 dez. 2022.

- CHAIM, A. **História da pulverização**. Embrapa, 1999. Disponível em: [https://www.agencia.cnptia.embrapa.br/recursos/Chaim\\_historiaID-Dcdtr0CVWI.pdf](https://www.agencia.cnptia.embrapa.br/recursos/Chaim_historiaID-Dcdtr0CVWI.pdf). Acesso em: 25 jun. 2021.
- CHARETTE, R. N. **Why software fails**. IEEE Spectrum, v. 42, n. 9, p. 42–49, set. 2005. Acesso em: 1 nov. 2021.
- CHASE. O. **Sistemas embarcados**. Sba Jovem. 2010. Disponível em: <http://www.lyfreitas.com.br/ant/pdf/Embarcados.pdf>. Acesso em: 11jan. 2023.
- CHEN, C. **Wiley interdisciplinary reviews: computational statistics**. (2010). Acesso: 14jul. 2021.
- CHRISTIE, M. **Ciências atmosféricas**. Disponível em: [https://meteorologia.unifei.edu.br/pag/altura\\_nuvem/calc.php](https://meteorologia.unifei.edu.br/pag/altura_nuvem/calc.php). Acesso em: 1 fev. 2023.
- ČOLAKOVIĆ, A.; HADŽIALIĆ, M. **internet of things (iot): a review of enabling technologies, challenges, and open research issues**. Computer Networks, v. 144, p. 17–39, out. 2018. Acesso em: 8 nov. 2022.
- CONTI, J. B.; FURLAN, S. **O clima: a atmosfera e a vida terrestre**. In: ROSS, Jurandir Luciano Sanches (Org). Geografia do Brasil. 5.ed. São Paulo: Edusp, 2008. p.69-110. Acesso em: 22abr. 2022.
- CONTIERO, R.L., BIFFE, D.F., CATAPAN, V. **Tecnologia de aplicação**. In: BRANDÃO FILHO, J.U.T., FREITAS, P.S.L., BERIAN, L.O.S., and GOTO, R., comps. Hortaliças-fruto [online]. Maringá: EDUEM, 2018, pp. 401-449. ISBN: 978-65-86383-01-0. <https://doi.org/10.7476/9786586383010.0015>. Acesso em: 28ago. 2021.
- CREPALDI, P. et al. **Um estudo sobre a árvore de decisão e sua importância na habilidade de aprendizado**. [s.l: s.n.]. Disponível em: [https://www.inesul.edu.br/revista/arquivos/arq-idvol\\_15\\_1320100263.pdf](https://www.inesul.edu.br/revista/arquivos/arq-idvol_15_1320100263.pdf). Acesso em: 13 fev. 2023.
- CORRÊA, M. P. *et al.* **Por que lançar satélites para observações meteorológicas?** Divisão de Satélites e Sistemas Ambientais – Centro de Previsão de Tempo e Estudos Climáticos, [s. l.], 2006. Disponível em: [http://mtc-m16b.sid.inpe.br/col/sid.inpe.br/iris@1915/2006/01.12.15.49/doc/Resumo\\_correa-machado-souza\\_57raSBPC.pdf](http://mtc-m16b.sid.inpe.br/col/sid.inpe.br/iris@1915/2006/01.12.15.49/doc/Resumo_correa-machado-souza_57raSBPC.pdf). Acesso em: 10 fev. 2023.
- CUNHA, J. P. A. R. **Simulação da deriva de agrotóxicos em diferentes condições de pulverização**. Ciência e agrotecnologia, Lavras, v. 32, n. 5, p. 1616-1621, 2008. DOI: <https://doi.org/10.1590/S1413-70542008000500039>. Disponível em: <https://www.scielo.br/j/cagro/a/NTGKZQsrSFvBjY57fDNQdyL/abstract/?lang=pt>. Acesso em: 22 jul. 2022.
- ELMASRI, R; NAVATHE, S. B. **Sistemas de banco de dados**. 6. ed. São Paulo: Pearson, 2011. Acesso em: 25 fev. 2023.
- FACHIN, R. **Agricultura 4.0: revolução tecnológica no campo**. [S. l.], 2021. Acesso em: 21 ago. 2021.

FERMARC. **Sensor de umidade do solo - resistente à corrosão**. Disponível em: <https://www.fermarc.com/sensor-de-umidade-do-solo-resistente-a-corrosao>. Acesso em: 23 fev. 2023.

FERRÉ, F. **Sistema gerenciador de banco de dados - sgbd | modelagem de coortes com dados administrativos**. Acesso em 10 fev. 2023.

FEW, S.; EDGE, P. **Dashboard confusion revisited**. (2007). Perceptual Edge, pg 1–6. Acesso em 13 fev. 2023.

FILHO, W. P. **Engenharia de software**: 4ª edição. Rio de Janeiro: LTC, 2019. Acesso em 22 jan. 2023.

FRANÇA, J. A. L.; CUNHA, J. P. A. R. DA; ANTUNIASSI, U. R. **Spectrum, velocity and drift of droplets sprayed by nozzles with and without air induction and mineral oil**. Engenharia Agrícola, v. 37, p. 502–509, 2017. Disponível em: <https://www.scielo.br/j/eagri/a/5HtZ3cZyf3FhHh4MdT5pq9J/?format=pdf&lang=en>. Acesso em: 21 ago. 2022.

GEURTS, P.; ERNST, D.; WEHENKEL, L. **Extremely randomized trees**. 2005. Acesso em: 19 fev. 2023.

GITIRANA, J. N. et al. **Deposição de calda promovida por pulverizadores empregados na cafeicultura de montanha**. [www.sbicafe.ufv.br](http://www.sbicafe.ufv.br), 1 abr. 2016. Acesso em: 4 mai. 2021.

GITHUB. **Projeto utfpr**. Disponível em: <https://github.com/evandrodasilvadossantos2023/ProjetoUTFPR2023>. Acesso em: 20 abr. 2023.

GOSUR. **Previsão do tempo e radar ao vivo**. Disponível em: <https://satellite-map.gosur.com/pt/>. Acesso em: 04 ago. 2022.

GRACIANO, A. F. **Rede sem fio 802.11ac em malha: com equipamentos de dupla banda de baixo custo**. 2015. Monografia (Pós-Graduação) - universidade tecnológica federal do paraná, [s. l.], 2015. disponível em: [https://repositorio.utfpr.edu.br/jspui/bitstream/1/19977/1/ct\\_teleinfo\\_1\\_2014\\_01.pdf](https://repositorio.utfpr.edu.br/jspui/bitstream/1/19977/1/ct_teleinfo_1_2014_01.pdf). Acesso em: 12 fev. 2023.

HAAS, J. et al. **Análise do risco climático de deriva em pulverização agrícola nas regiões sul e centro-oeste do Brasil**. [s.l.: s.n.]. Disponível em: <https://portaleventos.uffs.edu.br/index.php/JORNADA/article/view/16614/11151>. Acesso em: 4 dez. 2022.

HASTIE, T; TIBSHIRANI; R, FRIEDMAN. J. **The elements of statistical learning: data mining, inference and prediction**. New York: Springer New York; 2008. Acesso em: 22 dez. 2021.

HOLLIMAN, C. **Nonuniform dependence and well posedness for the periodic Hunter-Saxton equation**. Differential and Integral Equations, v. 23, n. 11/12, 1 nov. 2010. Acesso em: 9 out. 2022.

HORTA, D; CAMPELLO, R. J. G. B. **Automatic aspect discrimination in data clustering**. Pattern Recognition, v. 45, p. 4370-4388, 2012. Acesso em: 24 set. 2022.

INSTITUTO NACIONAL DE METEOROLOGIA DO BRASIL – INMET.

**Normas climatológicas** (1961/2019). Brasília - DF, 2022. Acesso em: 27 dez. 2022.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4th ed. Upper Saddle River, New Jersey: Prentice-Hall, 1999, 815 p. Acesso em: 3 jan. 2023.

JUPYTER, **Jupyter home page**. 2023. Disponível em: <https://jupyter.org/index.html>. Acesso em: 18 fev. de 2023.

KAPPEL et al.; G. **Web engineering: the discipline of systematic development of web applications**. Alemanha: John Wiley & Sons Ltd. All, 2003. Acesso em: 28 out. 2021.

KHANNA, A; KAUR, S. **Evolution of internet of things (iot) and its significant impact in the field of precision agriculture**. Computers and electronics in agriculture, v. 157, p. 218231, 2019. Acesso em: 18 dez. de 2022.

KHATTREE, R. & NAIK, D.N. **Multivariate data reduction and discrimination with SAS software**. Cary, NC, USA: SAS Institute Inc., 2000. 558 p. Acesso em: 17 mai. de 2022.

KNIGHT, J. C. **Dependability of embedded systems**. Proceedings of the 24th International Conference on Software Engineering. Orlando, Florida, 2002. Acesso em: 1 nov. 2021.

KNIPPELBERG, F.M; JUNIOR, J.H.C. **Estações meteorológicas: funcionamento e sua importância na agricultura**. Universidade Federal de Mato Grosso - UFMT, [S. l.], p. 1-6, 28 nov. 2019. Acesso em: 7 out. 2021.

KOHONEN, T. K. **The self-organizing map**. Proceedings of the IEEE, v. 78, n. 9, p. 1464- 1480, Sept. 1990. Acesso em: 15 jun. 2021.

KUHN, M; JOHNSON; K. **Applied predictive modeling**. (Springer, ed.). New York, NY: Springer New York; 2013. Acesso em: 1 ago. 2021.

LANGER, M. P. **Tecnologias e protocolos de comunicação para redes de sensores sem fio aplicados à cenários agrícolas**. 2021. Dissertação (Mestrado em Tecnologias Computacionais para o Agronegócio) Universidade Tecnológica Federal do Paraná. Acesso em: 10 dez. 2022.

LEE, E. A. **Embedded software**. Advances in Computers Vol. 56 (2002): Pg. 55-95. Acesso em: 12 dez. 2022.

LI, Q. **Real time concepts for embedded systems**. CMPBooks, 2003. Acesso em: 16 mai. 2021.

LIMA, F. R. **implementação de rede mesh para comunicação wireless entre máquinas de pátio de estocagem de minério de ferro**. Monografia (Bacharelado) - Faculdade Doctum de João Monlevade, [S. l.], 2019. Disponível em: <https://dspace.doctum.edu.br/bitstream/123456789/2059/1/TCC%20REDE%20MESH%20VERSAO%20FINAL%2020-07-2019.pdf>. Acesso em: 12 fev. 2023.

- LUNKES, J. A. **Efeito de subdoses de glyphosate e oxyfluorfen simulando deriva sobre a cultura do feijoeiro**. repositório.ufla.br, 15 fev. 2019. Acesso em: 27nov. 2021.
- LUDERMIR, T.B. **Inteligência artificial e aprendizado de máquina: estado atual e tendências**. Estudos Avançados, v. 35, p. 85-94, 2021. Acesso em: 10 fev. 2023.
- Malik, S. **Enterprise dashboards: design and best practices for IT**. 2005. John Wiley & Sons. Acesso em: 1 fev. 2023.
- MARCONI, M. A; LAKATOS, E. M. **Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisa, elaboração, análise e interpretação de dados**. São Paulo: Atlas, 2002. Acesso em: 8 fev. 2023.
- MARIANO, D. **Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score**. BIOINFO - Revista Brasileira de Bioinformática e Biologia Computacional, jul. 2021. Acesso em: 12 fev. 2023.
- MARTINI, A. T. et al. **Aspectos relevantes da inspeção de pulverizadores agrícolas: impactos na precisão das pulverizações de agrotóxicos**. Acta Iguazu, v. 6, n. 4, p. 72–82, 15 dez. 2017. Acesso em: 25 fev. 2022.
- MATTOS, M. et al. **Geolocation-based sector selection for Vehicle-to-Infrastructure 802.11 ad communication**. Computer Communications, v. 193, p. 224-233, 2022. Acesso em: 13 dez. 2021.
- MATUO, T. **Técnicas de aplicação de defensivos agrícolas**. 1. ed. Jaboticabal: FUNEP, 1990. Acesso em: 2 abr. 2021.
- MATSUNAGA, E. **Wireless lan: estudo do padrão ieee 802.11**. Disponível em: [http://ric.cps.sp.gov.br/bitstream/123456789/1463/1/20122S\\_MATSUNAGAEduardoTadao\\_TCCPD1168.pdf](http://ric.cps.sp.gov.br/bitstream/123456789/1463/1/20122S_MATSUNAGAEduardoTadao_TCCPD1168.pdf). Acesso em: 12 fev. 2023.
- MARTINS, J. A. O.; GUARIENTI, G. S. S. **Introdução a banco de dados**. Secretaria de Tecnologia Educacional Universidade Federal de Mato Grosso, 2019. Disponível em: [https://educapes.capes.gov.br/bitstream/capes/564494/2/FASCICULO\\_Introducao\\_Banco\\_Dados\\_30\\_08.pdf](https://educapes.capes.gov.br/bitstream/capes/564494/2/FASCICULO_Introducao_Banco_Dados_30_08.pdf). Acesso em: 10 fev. 2023.
- MAVI, H. S.; TUPPER, G. J. **Agrometeorology: principles and applications of climate studies in agriculture**. New York: Food Products Press, 2004. Acesso em: 7 ago. 2021.
- MEGETO, G. A. S. et al. **Artificial intelligence applications in the agriculture 4.0**. REVISTA CIÊNCIA AGRONÔMICA, v. 51, n. 5, 2020. Acesso em: 23 out. 2021.
- MELLO, L. C. **Comparativa para tecnologia tdma**. 2002. Tese de Doutorado. PUC-Rio. MELO, Leonardo Cruz. **Comparativa para Tecnologia TDMA**. 2002. Tese de Doutorado. PUC-Rio. Acesso em: 10 fev. 2023.
- MENDES, R. M. MISKULIN, R. G. S. **A análise de conteúdo como uma metodologia**. Cadernos de Pesquisa, v. 47, p. 1044-1066, 2017. Disponível em: <https://www.scielo.br/j/cp/a/ttbmyGkhjNF3Rn8XNQ5X3mC/?lang=pt>. Acesso em: 11 fev. 2023.



MÉNDEZ, A. J. L. et al. **Coleta de chuva com registradores de cuvetes e seu pós-processamento**. Havana, 2013. Acesso em: 4jan. 2023.

MENDONÇA, F; OLIVEIRA, I. M. D. **Climatologia: Noções básicas e climas do Brasil**. São Paulo: Oficina de Textos, 2007. Acesso em: 19 out. 2021.

MENEZES, A. C. S. **Desenvolvimento e calibração de pluviômetros automáticos de baixo custo**. Orientador: Universidade Federal do Vale do São Francisco. 2019. Dissertação (Mestrado) - Universidade Federal do Vale do São Francisco, Campus Juazeiro –BA, [S. l.], 2019. Acesso em: 10fev. 2023.

MINEWISKAN. **Referência técnica do algoritmo de regressão linear da Microsoft**. Disponível em: <https://learn.microsoft.com/pt-br/analysis-services/data-mining/microsoft-linear-regression-algorithm-technical-reference?view=asallproducts-allversions>. Acesso em: 28nov. 2022.

MIRJALILI, V.; RASCHKA, S. **Machine learning and deep learning with python, scikit-learn, and tensor flow 2**. [S. l.]: PacktPublishing Ltd., 2019. ISBN 978-1-78995-575-0. Acesso: 20 fev. 2023.

MONTEIRO, J.E.B.A (org.). **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Instituto Nacional de Meteorologia – INMET: [s. n.], 2009. 546 p. ISBN 978-85-62817-00-7. Acesso: 5jan. 2021.

MONARD, M.C; BARANAUSKAS, J.A. **Conceitos sobre aprendizado de máquina**. Sistemas inteligentes-Fundamentos e aplicações, v. 1, n. 1, p. 32, 2003. Acesso em: 28 nov. 2022.

MONTEIRO, J.E.B.A; SENTELHAS, P.C (org.). **Agrometeorologia dos cultivos: informações para uma agricultura sustentável**. Instituto Nacional de Meteorologia – INMET: [s. n.], 2009. 546 p. ISBN 978-85-62817-00-7. Acesso: 16 jan. 2021.

MOREIRA, A. L. S. **Análise de sistemas operacionais de tempo real**. Dissertação (Mestrado) - Universidade Federal de Pernambuco, [S. l.], 2. Acesso: 25 jan. 2023.

NOBRE, C.; REID, J.; SOARES VEIGA, A. **Fundamentos científicos das mudanças climáticas**. 2012. Disponível em: [https://cetesb.sp.gov.br/proclima/wp-content/uploads/sites/36/2014/05/nobre\\_reid\\_veiga\\_fundamentos\\_2012.pdf](https://cetesb.sp.gov.br/proclima/wp-content/uploads/sites/36/2014/05/nobre_reid_veiga_fundamentos_2012.pdf). Acesso: 4 mai. 2021.

NOERGAARD, T. **Embedded Systems Architecture**. [s.l.] Elsevier, 2005. Acesso: 23 mai. 2021.

OKADA, H. K. R.; NEVES, A. R. N. DAS; SHITSUKA, R. **Analysis of decision tree induction algorithms. research, society and development**, v. 8, n. 11, p. 298111473, Acesso em: 24 ago. 2022.

OLENEWA, J; CIAMPA, M. **Wireless guide to wireless communications**. 2. Ed. United States of America: Boston: Course Technology, 2007. 506 p. Acesso: 22jan. 2023.

OLIVER, J. F.; FAIRBRIDGE, R. W. **Enciclopédia of climatology**. New York: V. N. Reinhold, 1987. Acesso: 2set. 2021.

ORACLE. **O que é um banco de dados?** Disponível em: <https://www.oracle.com/br/database/what-is-database/>. Acesso em: 18 fev. 2023.

PEREIRA, A.R.; ANGELOCCI, L R.; SENTELHAS, P.C. **Agrometeorologia – fundamentos e aplicações práticas**. Guaíba: Ed. Agropecuária. 2002. 478p. Acesso: 16ago. 2021.

PRECIPITO, L. M. et al. **Evaporation and wettability of fungicide spray, with or without adjuvant, on leaves of vegetables**. Horticultura Brasileira, v. 36, n. 3, p. 320–324, set. 2018. Acesso: 22set. 2021.

PROGRAMS. D.S.G. **Understanding how python is used in data science**. 2018. Acesso em: 18 fev. 2023.

RAMAMRITHAM, K., e J. A. STANKOVIC. **Scheduling algorithms and operating systems support for real-time systems**. Proceedings of The IEEE Vol. 82, n. 1 (janeiro, 1994). Acesso: 19nov. 2021.

RIBEIRO, A. G. **As escalas do clima**. Universidade de São Paulo - USP, [s. l.], 1993. Acesso: 11jan. 2023.

ROBOCORE. **RoboCore // A loja virtual do maker brasileiro**. Disponível em: <https://www.robocore.net>. Acesso em: 22 fev. 2023.

ROSA, R. P. **Dispositivos iot aplicáveis à agricultura intensiva e os resultados já alcançados**. [s.l.: s.n.]. Disponível em: [https://repositorio.animaeducacao.com.br/bitstream/ANIMA/4019/1/Artigo\\_Final\\_Rafael\\_Rosa\\_v3.pdf](https://repositorio.animaeducacao.com.br/bitstream/ANIMA/4019/1/Artigo_Final_Rafael_Rosa_v3.pdf). Acesso: 26jan. 2022.

RUSS, G.; KRUSE, R.; SCHNEIDER, M.; WAGNER, P. **Visualization of agriculture data using self-organizing maps**. In: ALLEN, T.; ELLIS, R.; PETRIDIS, M. (Ed.). Applications and Innovations in Intelligent Systems. London: Springer, 2009. p. 47-60. Acesso: 23 jul. 2021.

RUSSELL. S. J; NORVIG, P. **Artificial intelligence: a modern approach**. Boston: Pearson, Cop, 2010. Acesso: 22dez. 2022.

SABARÁ, H. B.; SANTOS, F. C. **Tecnologia no campo, sistemas de automação e informatização**. repositorio.unifaema.edu.br, 2021. Acesso: 1mai. 2022.

SABIK, H.; JEANNOT, R.; RONDEAU, B. **Multiresidue methods using solid-phase extraction techniques for monitoring priority pesticides, including triazines and degradation products, in ground and surface waters**. Journal of Chromatography A, v. 885, n. 1-2, p. 217–236, jul. 2000. Acesso: 5nov. 2021.

SANCHES, S. R. **Sistema de transmissão de dados meteorológicos em tempo real para celulares de usuários de marinas**. Orientador: Cássio Aurélio Suski. 2020. Dissertação (Mestrado Profissional) - Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina, [S. l.], 2020. Acesso: 20dez. 2022.

SANTIAGO, H.; GUAZZELLI, T.M. **Simulação de perda por evaporação com diferentes caldas e adjuvantes agrícolas**. Centro Científico Conhecer, AgrarianAcademy, p. 1-10, 30 dez. 2021. DOI 10.18677/Agrarian\_Academy\_2021B7. Disponível em:

<http://www.conhecer.org.br/Agrarian%20Academy/2021B/simulacao.pdf>. Acesso em: 4 dez. 2021.

SANTOS, H. G. **Comparação da performance de algoritmos de Machinelearning para a análise preditiva em saúde pública e medicina**. [s.l.: s.n.]. Disponível em: [https://www.teses.usp.br/teses/disponiveis/6/6141/tde-09102018-132826/publico/HellenGeremiasdosSantos\\_DR\\_ORIGINAL.pdf](https://www.teses.usp.br/teses/disponiveis/6/6141/tde-09102018-132826/publico/HellenGeremiasdosSantos_DR_ORIGINAL.pdf). Acesso em: 6out. 2022.

SCIKIT-LEARN: **Machine learning in python**— scikit-learn 0.22.2 documentation. Disponível em: <https://scikit-learn.org>. Acesso em: 3jan. 2023.

SILBERSCHATZ, A.; KORF, H. F.; SUDARSHAN, S. **Sistemas de banco de dados**, 6ª. Ed. Elsevier, 2012. Acesso: 9 fev. 2023.

SILVA, A. R. C. **Predição de localização de crimes em região urbana usando algoritmos de análise de regressão**. 2020. Monografia (Bacharelado) - UNIVERSIDADE FEDERAL DO CEARÁ, [S. l.], 2020. Acesso: 23mai. 2022.

SIVAKUMAR et. al. **Agrometeorology and sustainable agriculture**. Agricultural and Forest Meteorology, 103, 11-26, 2000. Acesso: 30jun. 2022.

SOUZA, A. **Meteorologia e climatologia agrícola**. Instituto Formação: [s. n.], 2012. Acesso em: 24 nov. 2022.

SPANAKI, K.; KARAFILI, E.; DESPOUDI, S. **AI applications of data sharing in agriculture 4.0: A framework for role-based data access control**. International Journal of Information Management, v. 59, p. 102350. Acesso em: 4 out. 2022.

STALLINGS, W. **Operating systems: internals and design principles**. Pearson Prentice Hall, 2008. Acesso em: 22 out. 2021.

SUMNER, P. E.; SUMNER, S. A. **Comparison of new drift reduction nozzles**. St. Joseph: ASAE, 1999. 17 p. Acesso: 29nov. 2022.

SUNDMAEKER, H. et al. **Internet of food and farm 2020**. Digitising the Industry-Internet of Things connecting physical, digital and virtual worlds. Ed: Vermesan, O., & Friess, P, p. 129151, 2016. Acesso em: 18nov. 2022.

UISP. **Design center**. Disponível em: <https://ispdesign.ui.com/#>. Acesso em: 22 ago. 2021.

UBIQUITI. Disponível em: <https://ubiquiti.com>. Acesso em: 21 fev. 2023.

VARGAS, L; GLEBER, L. **Sistema de produção de ameixa europeia: tecnologia de aplicação de defensivos**. Embrapa, 2005. Disponível em: <https://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Ameixa/AmeixaEuropeia/tecnologia.htm>. Acesso em: 24 nov. 2022.

VAPNIK, V. **The nature of statistical learning theory**. New York: Springer-Verlag, 1995. BROWN, M.; LEWIS, H.G.; GUNN, S.R. Linear spectral mixture models and support vector machines for remote sensing. IEEE Transactions on geoscience and remote sensing, v. 38, n. 5, p. 2346-2360. 2000. Acesso: 1set. 2022.

VEIGA, M. M. **Agrotóxicos: eficiência econômica e injustiça socioambiental**. *Ciência&SaúdeColetiva*, v. 12, p. 145–152, 1 mar. 2007. Acesso: 21 ago. 2022.

WOLF, W. **The good news and the bad news**. *Computer*, outubro de 2007: pg. 104-105. Acesso em: 22 out. 2021.

ZHANG et al. **Numerical simulation of spray drift and deposition from a crop spraying aircraft using a CFD approach**. *Biosystems engineering*, v. 166, p. 184–199, 2018. Acesso em: 19 out. 2021.

## **APÊNDICE A - Torre de distribuição WI-FI I**



Fonte: Autoria própria (2023)

## **APÊNDICE B - Torre de distribuição WI-FI II**



Fonte: Autoria própria (2023)



## **APÊNDICE C - Estação metereologica I**



Fonte: Autoria própria (2023)

## **APÊNDICE D - Estação metereologica II**



Fonte: Autoria própria (2023)


## **APÊNDICE E - Estação metereologica III**





Fonte: Autoria própria (2023)

## **APÊNDICE F - Estação metereologica IV**



Fonte: Autoria própria (2023)



**APÊNDICE G - Página inicial**



Fonte: Autoria própria (2023)

**APÊNDICE H - Painel de controle**

The dashboard, titled 'i-Cida', is accessed by an 'Administrador' user. It features a sidebar with navigation options: Painel de Controle, AM, Satélite, Dados Globais, Localização, Monitoramento, and Sobre. The main content area, 'Painel de Controle', is divided into two columns. The left column is headed 'CHUVA' and contains weather-related metrics: 'Previsão do Tempo' (with a sun icon), '25.1 °C' (Temperatura), '20.41 °C' (Ponto de Orvalho), and '564.72 m' (Formação das Nuvens). The right column is headed 'SIM' and contains system-related metrics: 'Random Forest Classifier' (with a bug icon), '942.38 Hpa' (Pressão Atmosférica), '8 Km/H' (Velocidade do Vento), and 'ERROR!' (Internet Local). A third row of metrics includes '76.27 %' (Umidade Relativa), '0 mm' (Índice Pluviométrico (acum.)), '24.3 %' (Umidade do Solo), '28.11 °C' (Sensação Térmica), and 'Oeste' (Direção do Vento). A 'Conectado' status is shown for the 'Banco de Dados'. A weather widget on the left shows 'Tempo Ceu Azul' with temperatures of 26° and 18°, and a forecast for 'QUINTA' with 26° and 19°. The time is 21:39:24 on 22/02/2023.

CHUVA		SIM	
Previsão do Tempo	Random Forest Classifier		
25.1 °C Temperatura	76.27 % Umidade Relativa	942.38 Hpa Pressão Atmosférica	28.11 °C Sensação Térmica
20.41 °C Ponto de Orvalho	0 mm Índice Pluviométrico (acum.)	8 Km/H Velocidade do Vento	Oeste Direção do Vento
564.72 m Formação das Nuvens	24.3 % Umidade do Solo	ERROR! Internet Local	Conectado Banco de Dados

Fonte: Autoria própria (2023)

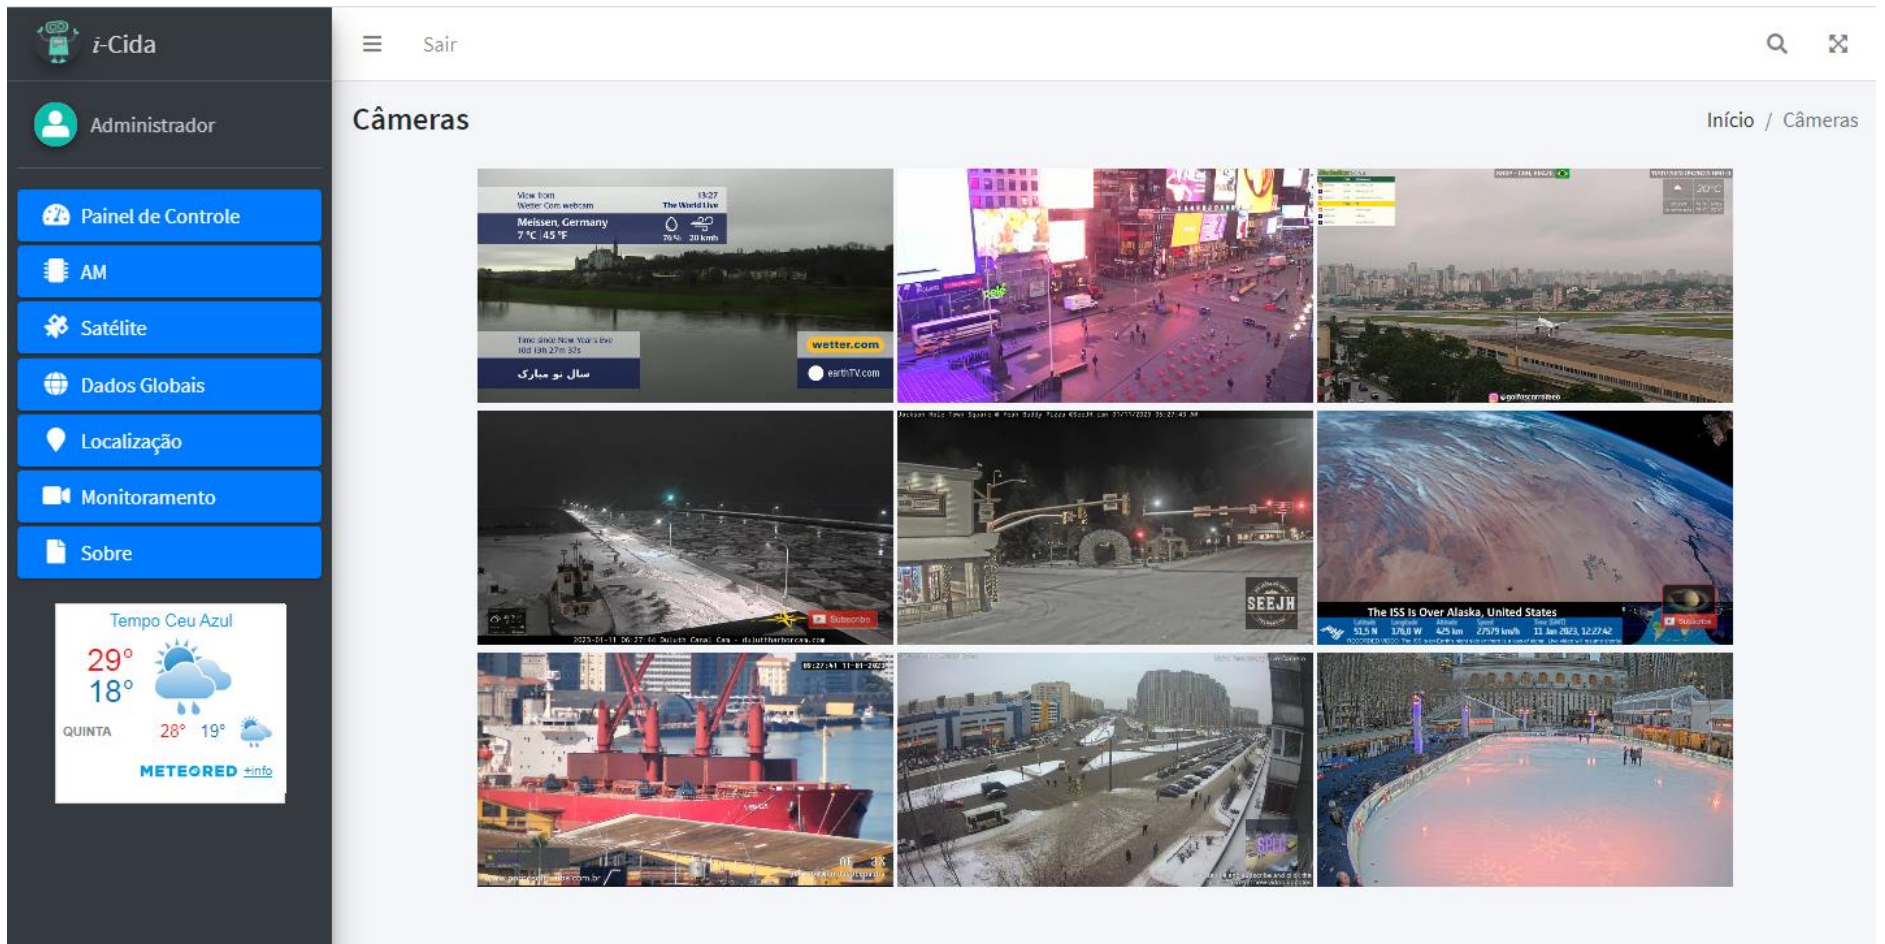
**APÊNDICE I - Tela aprendizagem de máquina**

The screenshot shows a web interface for machine learning management. On the left is a dark sidebar with a user profile 'Administrador' and a menu with items: 'Painel de Controle', 'AM', 'Satélite', 'Dados Globais', 'Localização', 'Monitoramento', and 'Sobre'. Below the menu is a weather widget for 'Tempo Ceu Azul' showing 26°C and 18°C. The main area is titled 'Aprendizagem de Máquina' and contains a 3x4 grid of green cards, each representing a machine learning model with its status and a lightbulb icon.

Modelo	Status
Decision Tree Classifier	SIM
Decision Tree Regressor	SIM
Extra Tree Classifier	SIM
Gaussian NB	SIM
Linear Discriminant Analysis	NÃO
Linear Regression	NÃO
Logistic Regression	DESATIVADO
One Class SVM	DESATIVADO
Random Forest Classifier	SIM
Random Forest Regressor	SIM
Support Vector Machines	DESATIVADO
Ultima Leitura	2023-02-22 10:50:47

Fonte: A autoria própria (2023)

**APÊNDICE J - Exemplo de monitoramento**



Fonte: Autoria própria (2022)



**APÊNDICE K - Tela sobre**

**Iagritech** Sair

Administrador

- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul  
 26°  
 18°  
 QUINTA 26° 19°  
 METEORED info

Hora: 21:52:12 Data: 22/02/2023

## Sobre o Projeto

### Aplicação de aprendizagem de máquina em sistemas embarcados no auxílio à pulverização agrícola

#### Resumo

Este projeto tem como objetivo a implantação de aprendizagem de máquina com dados de estação meteorológica, buscando melhorar a eficiência na aplicação de defensivos agrícolas com a análise dos dados coletados em tempo real, reduzindo assim a deriva, diminuindo os riscos de contaminação ambiental, da exposição direta e indireta aos seres humanos, e proporcionando maior economia ao produtor rural. Para a realização deste trabalho, será confeccionado uma estação meteorológica somada a sensores de umidade do solo, as quais fornecem dados ao aplicativo I-CIDA, também desenvolvido neste projeto. O algoritmo de aprendizagem de máquina será utilizado neste projeto, que consiste no aprendizado do sistema sem ser necessariamente programado. Ao final deste trabalho, espera-se que o sistema seja capaz de por si só decidir qual o melhor momento para aplicar os defensivos agrícolas, informando a resposta ao usuário pelo aplicativo.

#### Introdução

O crescimento populacional, e consequentemente a maior demanda por alimentos, faz com que haja necessidade de se obter maiores níveis de produtividade das áreas agrícolas. Isso leva os produtores a buscarem por técnicas mais eficientes as quais possibilitem satisfazer as necessidades nutricionais, o aumento da produtividade em áreas já exploradas e a garantia da qualidade dos alimentos para o mercado interno e externo.

Porém, para se atingir produções satisfatórias de alimentos em escala comercial, têm-se a necessidade de utilizar diversos métodos para o domínio do cultivo, sendo o uso de defensivos agrícolas no controle de plantas daninhas, insetos e doenças cada vez mais intenso. No entanto, o aumento do uso desses insumos, juntamente com a diversidade de produtos utilizados, é um problema a ser estudado, principalmente no que se refere à precisão das pulverizações.

O tratamento fitossanitário, para ser eficiente, não depende somente da quantidade de ingrediente ativo depositado no alvo, mas também da uniformidade e distribuição sobre a superfície a qual se deseja atingir. Dessa forma, os equipamentos de pulverização têm a função de distribuir o produto com tamanho de gotas adequado sobre esse alvo (FOLONI, 1995; RODRIGUES, 2006) e ao mesmo tempo, evitar que esse produto seja depositado fora do local desejado (deriva) e venha a ocasionar problemas ambientais e sociais.

**Fonte: Autoria própria (2022)**

**ANEXO A - Tela satélite**

The image shows a screenshot of a weather application interface. On the left is a dark sidebar menu with the following items: 'i-Cida' (with a person icon), 'Administrador' (with a person icon), 'Painel de Controle', 'AM', 'Satélite', 'Dados Globais', 'Localização', 'Monitoramento', and 'Sobre'. Below the menu is a weather widget for 'Tempo Ceu Azul' showing a current temperature of 29° and a low of 18°, with a forecast for 'QUINTA' showing 28° and 19°. The main area is titled 'Satélite' and displays a satellite radar map of South America. The map shows radar returns over Paraguay, Uruguay, and parts of Brazil and Argentina. Major cities labeled include Salta, San Miguel Tucumán, Asunción, Ciudad del Este, Posadas, Curitiba, Florianópolis, Caxias do Sul, and Porto Alegre. A search bar at the top of the map area contains the text 'Digite um endereço, cidade ou país'. On the right side of the map, there is a vertical toolbar with icons for zooming, panning, and other map functions. At the bottom right, a small inset map shows the current location with coordinates: -21.549814° latitude and -44.834028° longitude.

Fonte: Gosur (2023)

**ANEXO B -Dados globais (GFS 2m Temperature °C)**

i-Cida

Administrador


- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

METEORED info



Fonte: ClimateReanalyzer (2023)

**ANEXO C -Dados globais (GFS Precipitation (mm/h), Clouds)**



i-Cida

Administrador


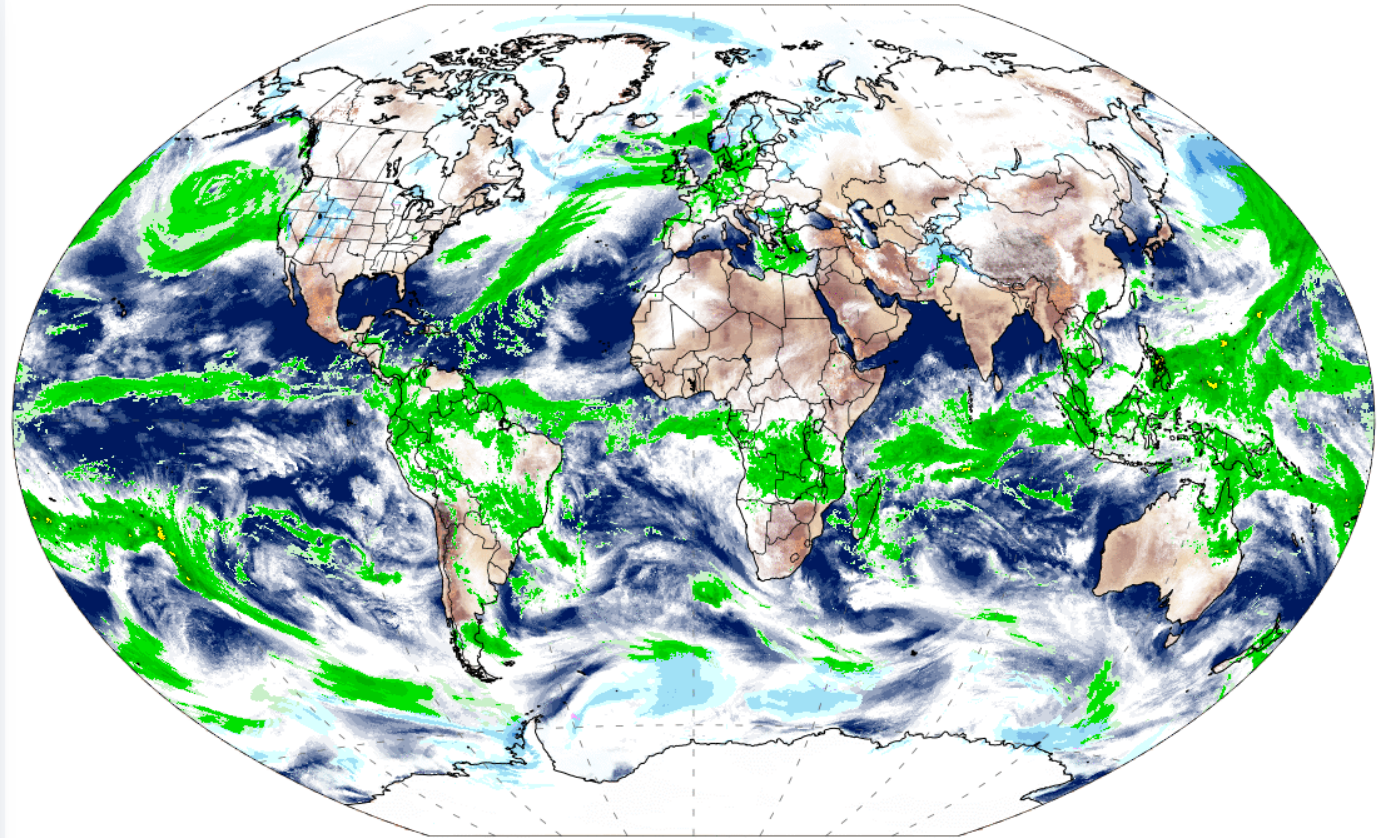
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

METEORED info



Fonte: ClimateReanalyzer (2023)



**ANEXO D - Dados globais (GFS 10m Wind Speed(kt))**

i-Cida

Administrador


- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceo Azul

29°  
18°

QUINTA 28° 19°

METEORED info



Fonte: ClimateReanalyzer (2023)

**ANEXO E - Globais (Last Glacial Maximum)**

**i-Cida**

Administrador

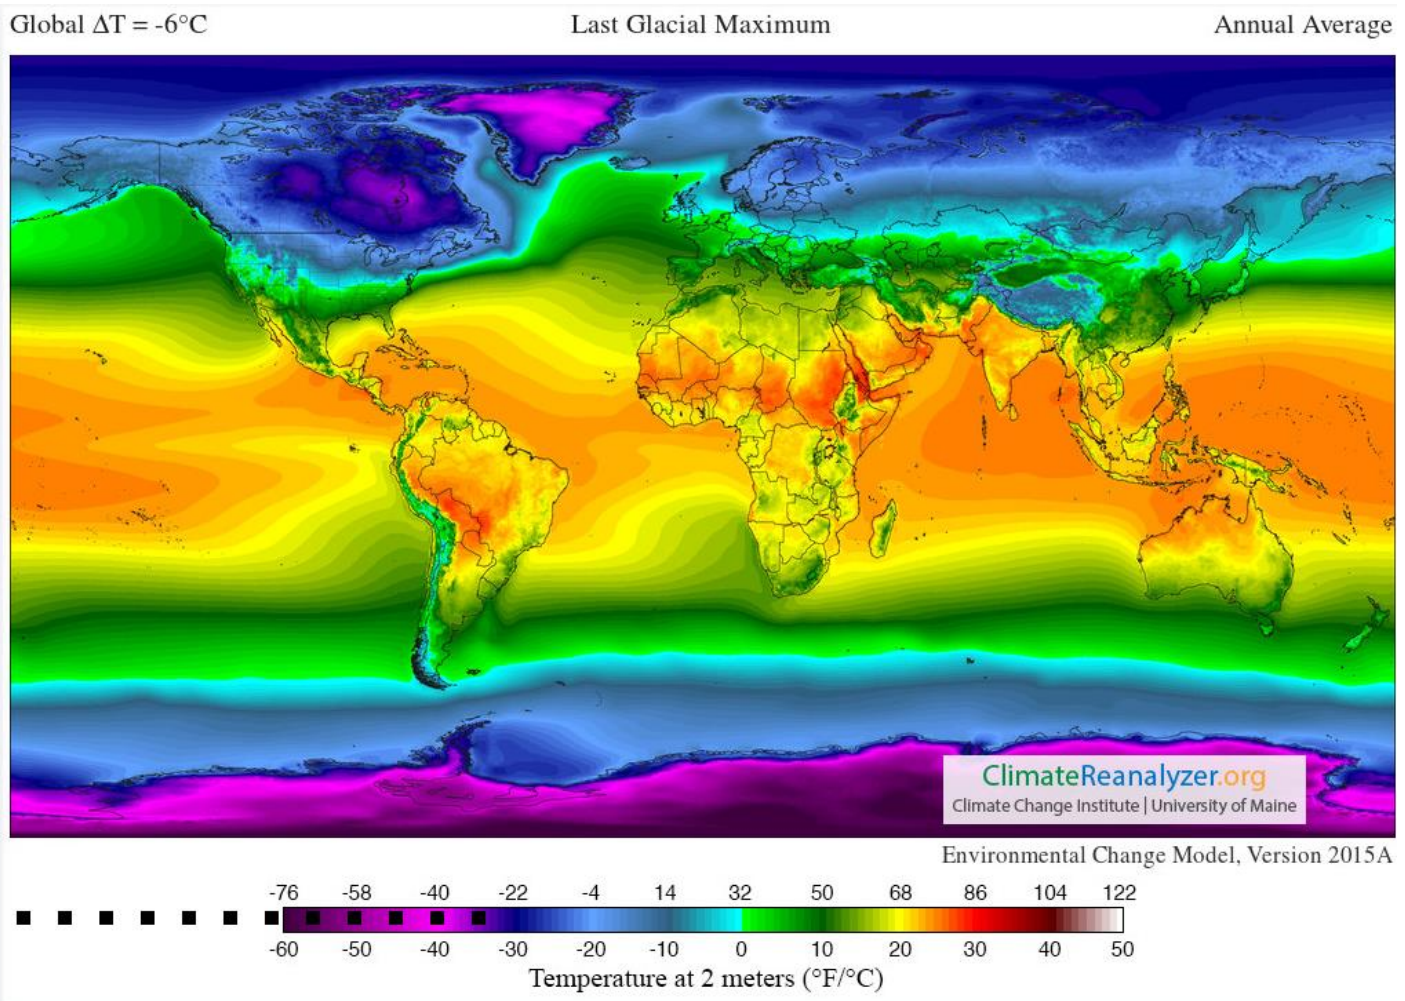
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

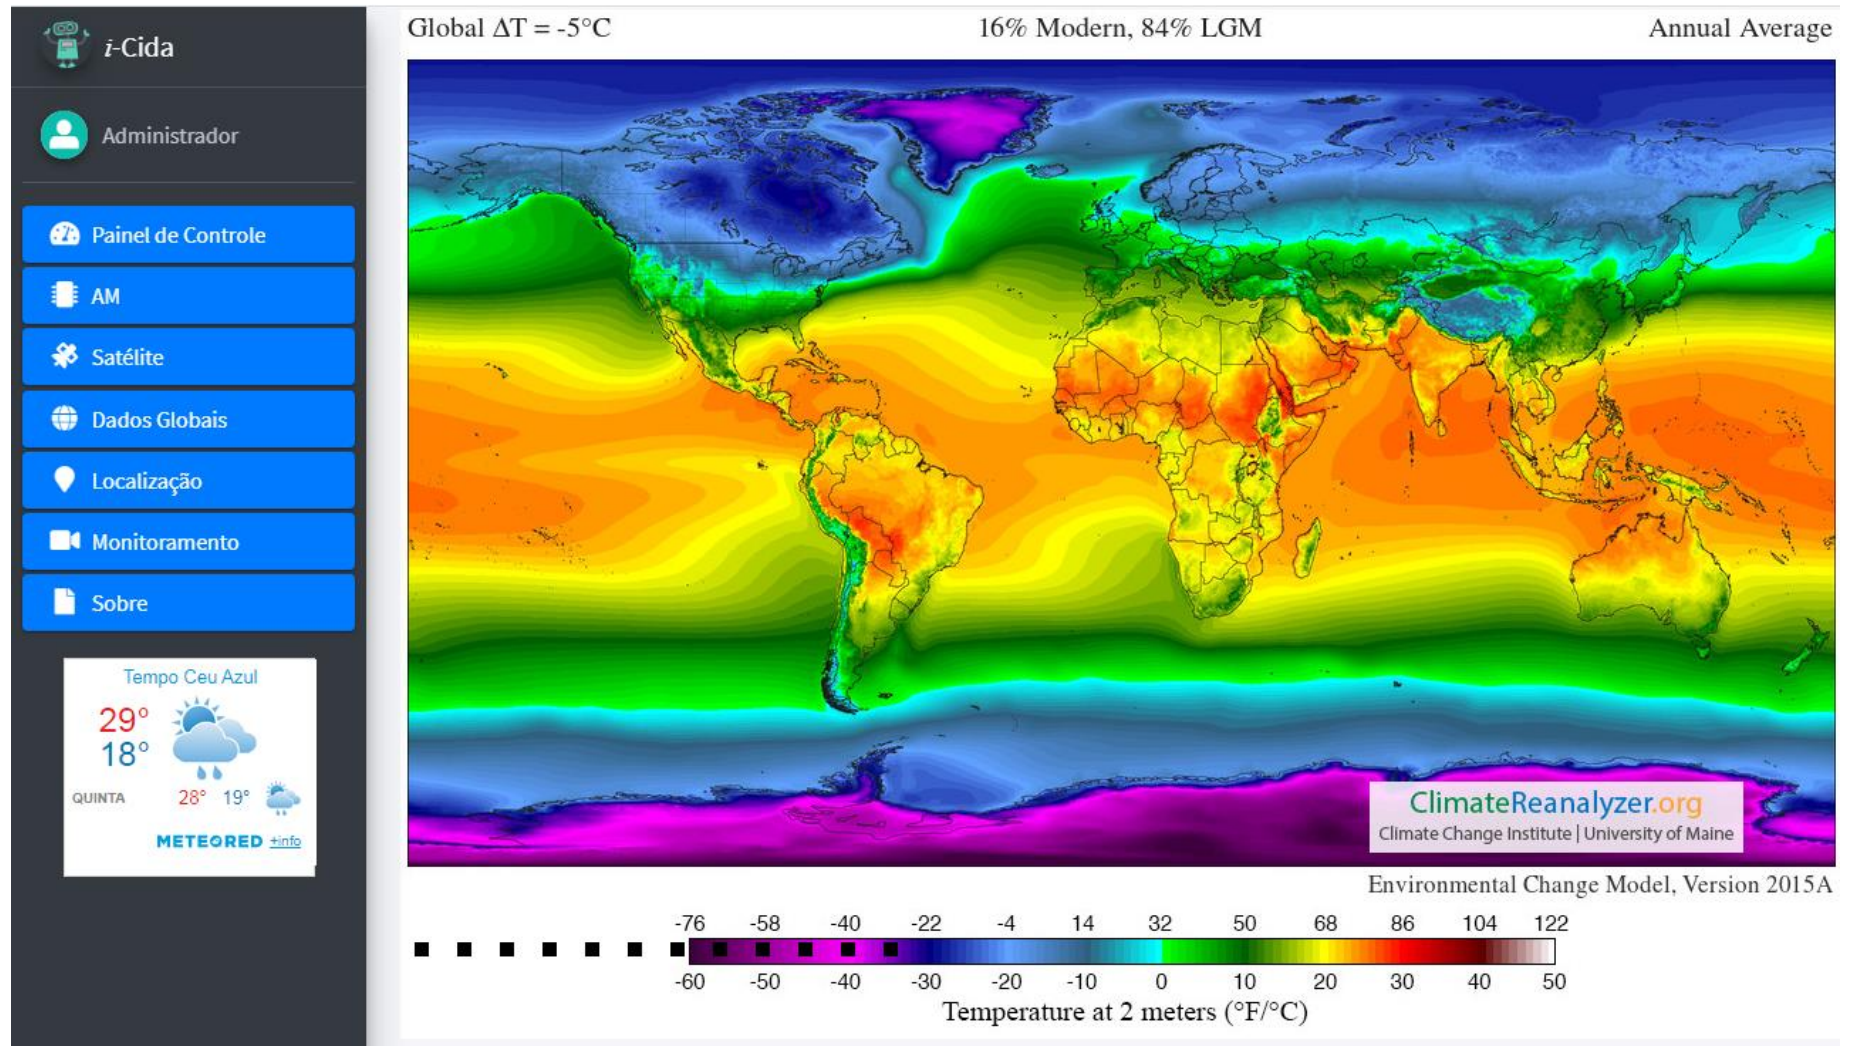
METEORED [info](#)



Fonte: ClimateReanalyzer (2023)

**ANEXO F - Dados globais (16% Modern, 84% LGM)**





Fonte: ClimateReanalyzer (2023)

**ANEXO G -Dados globais (33% Modern, 67% LGM)**

**i-Cida**

Administrador

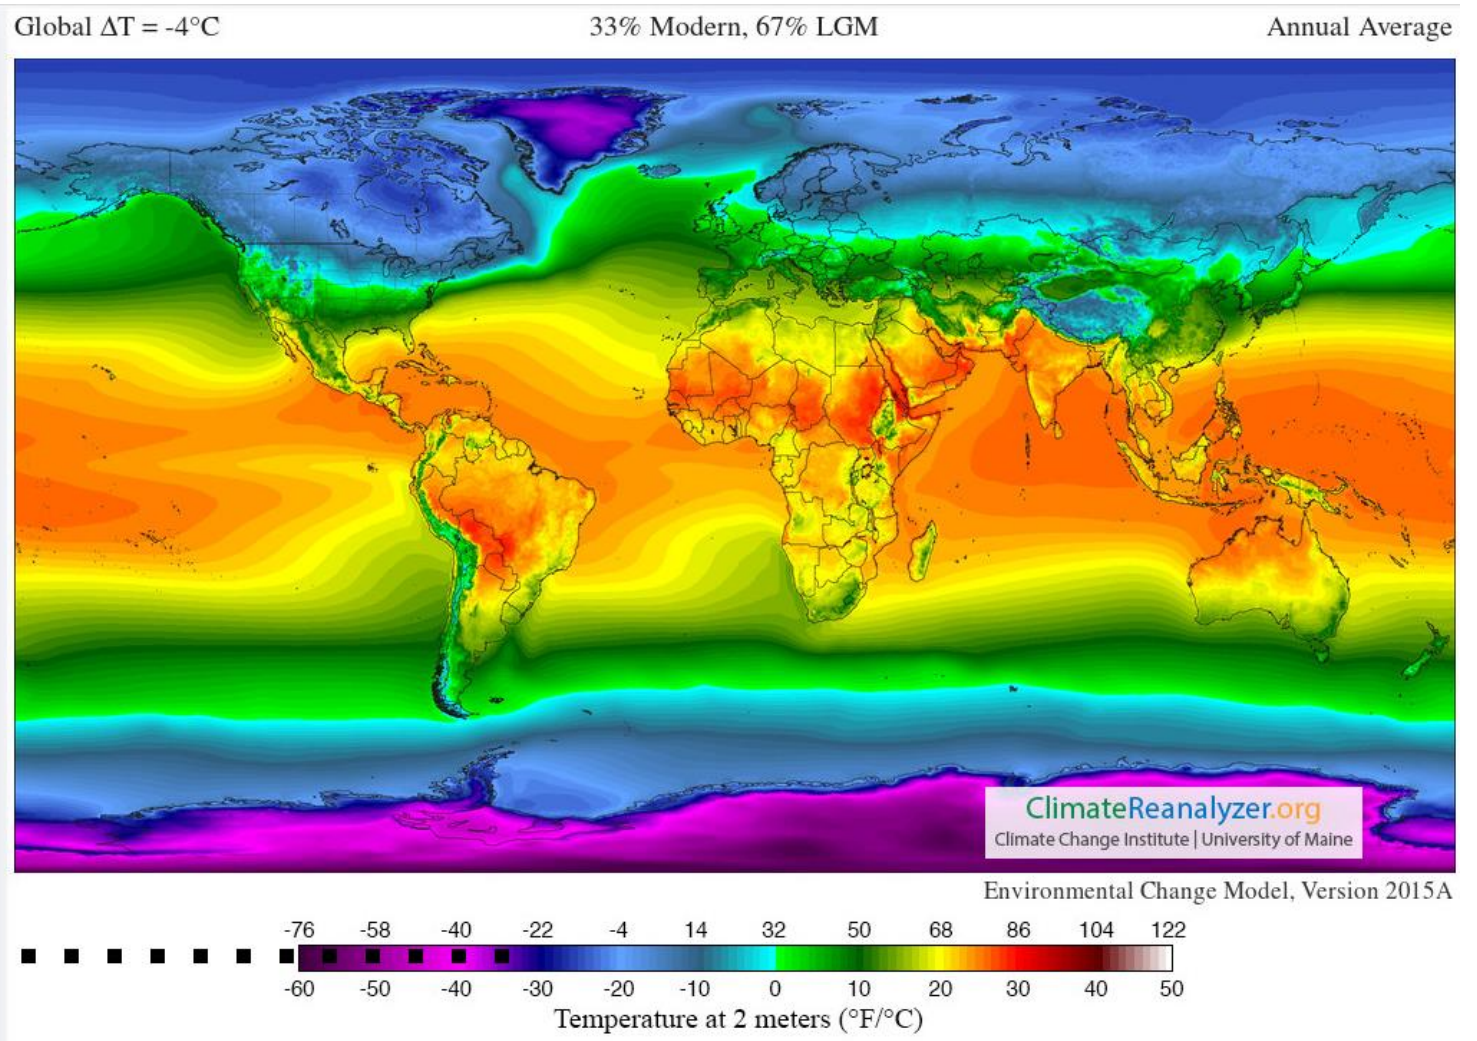
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

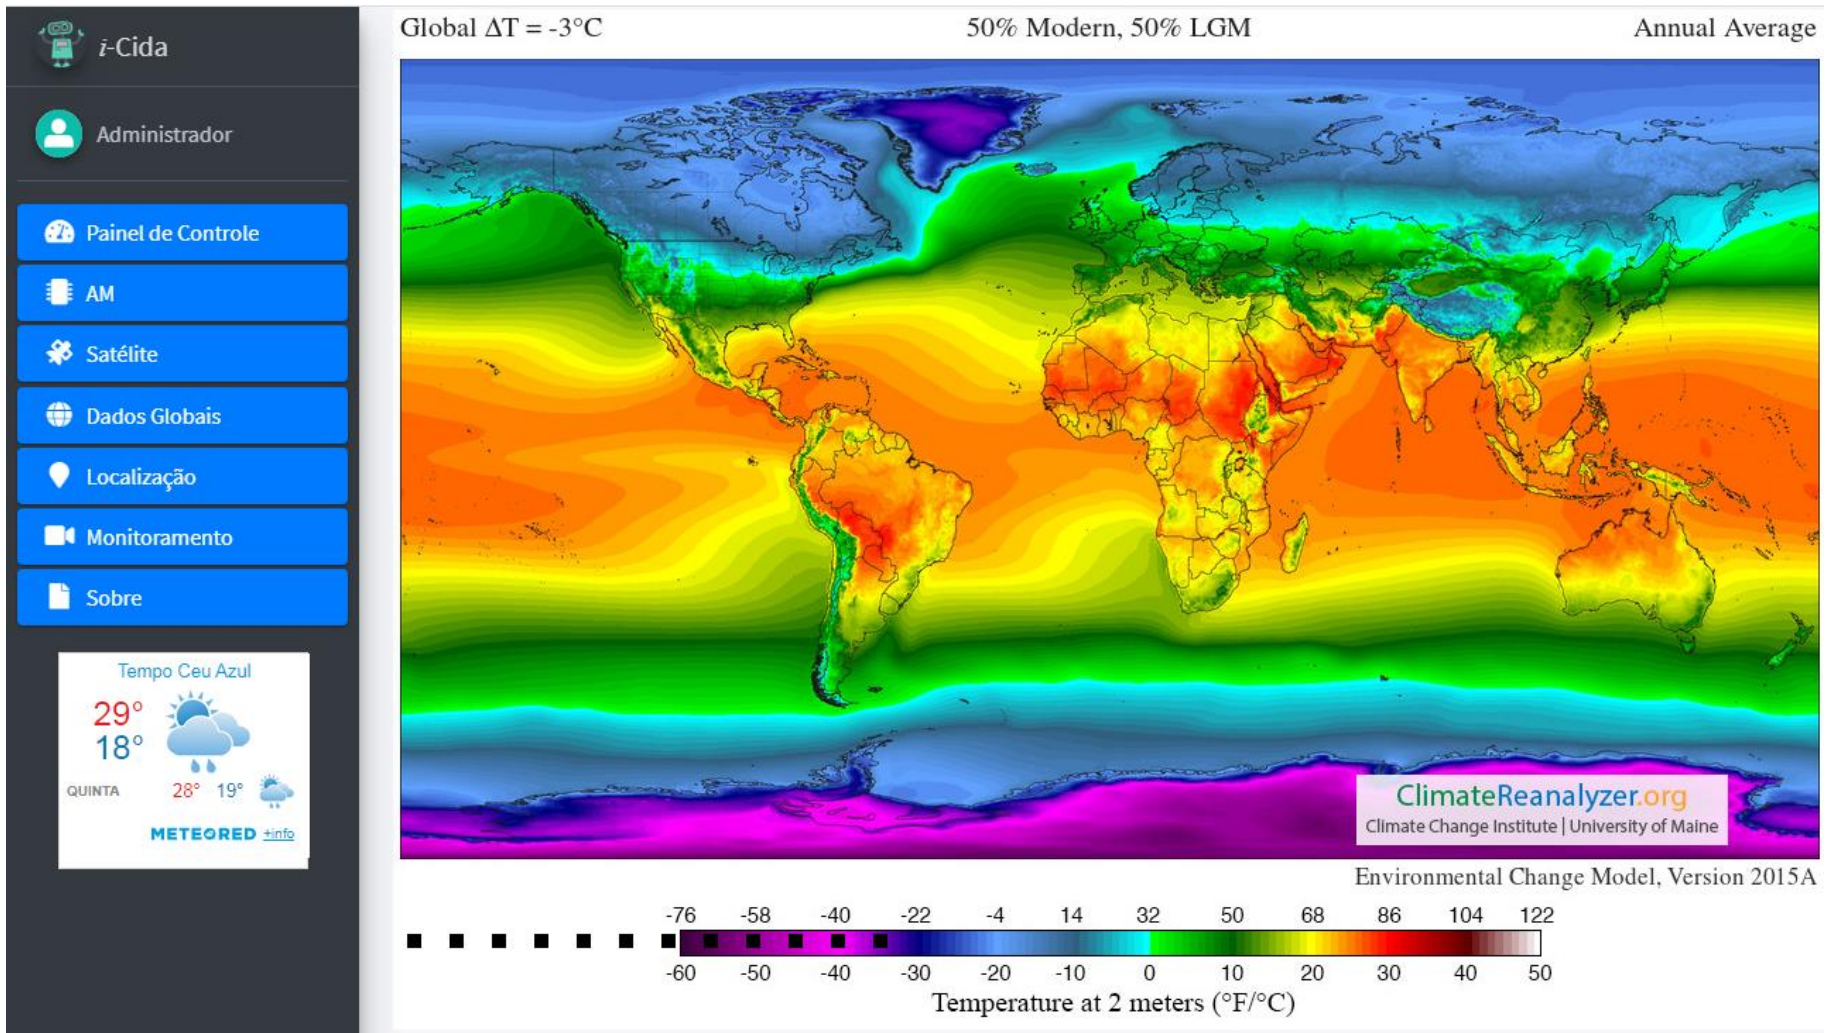
METEORED +info



Fonte: ClimateReanalyzer (2023)

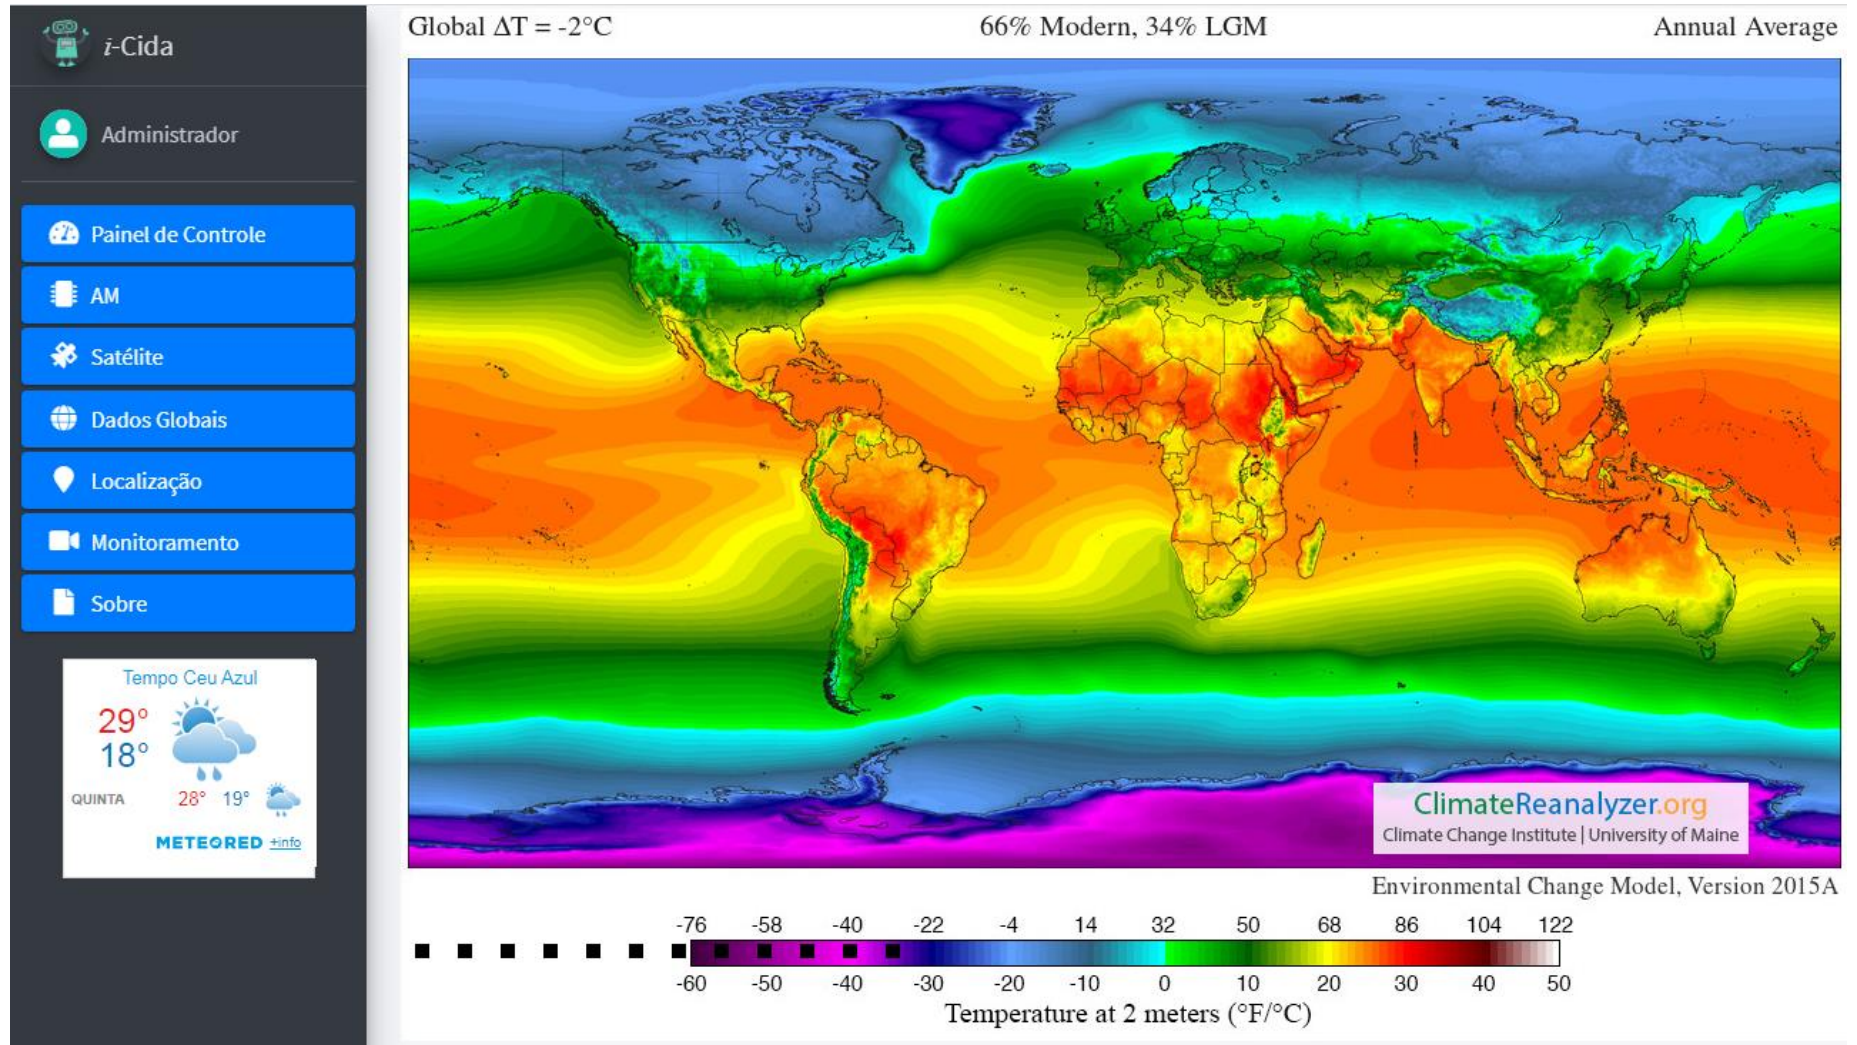


**ANEXO H -Dados globais (50% Modern, 50% LGM)**



Fonte: ClimateReanalyzer (2023)

**ANEXO I - Dados globais (66% Modern, 34% LGM)**



Fonte: ClimateReanalyzer (2023)

**ANEXO J - Dados globais (83% *Modern*, 17% *LGM*)**



**i-Cida**

Administrador

- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

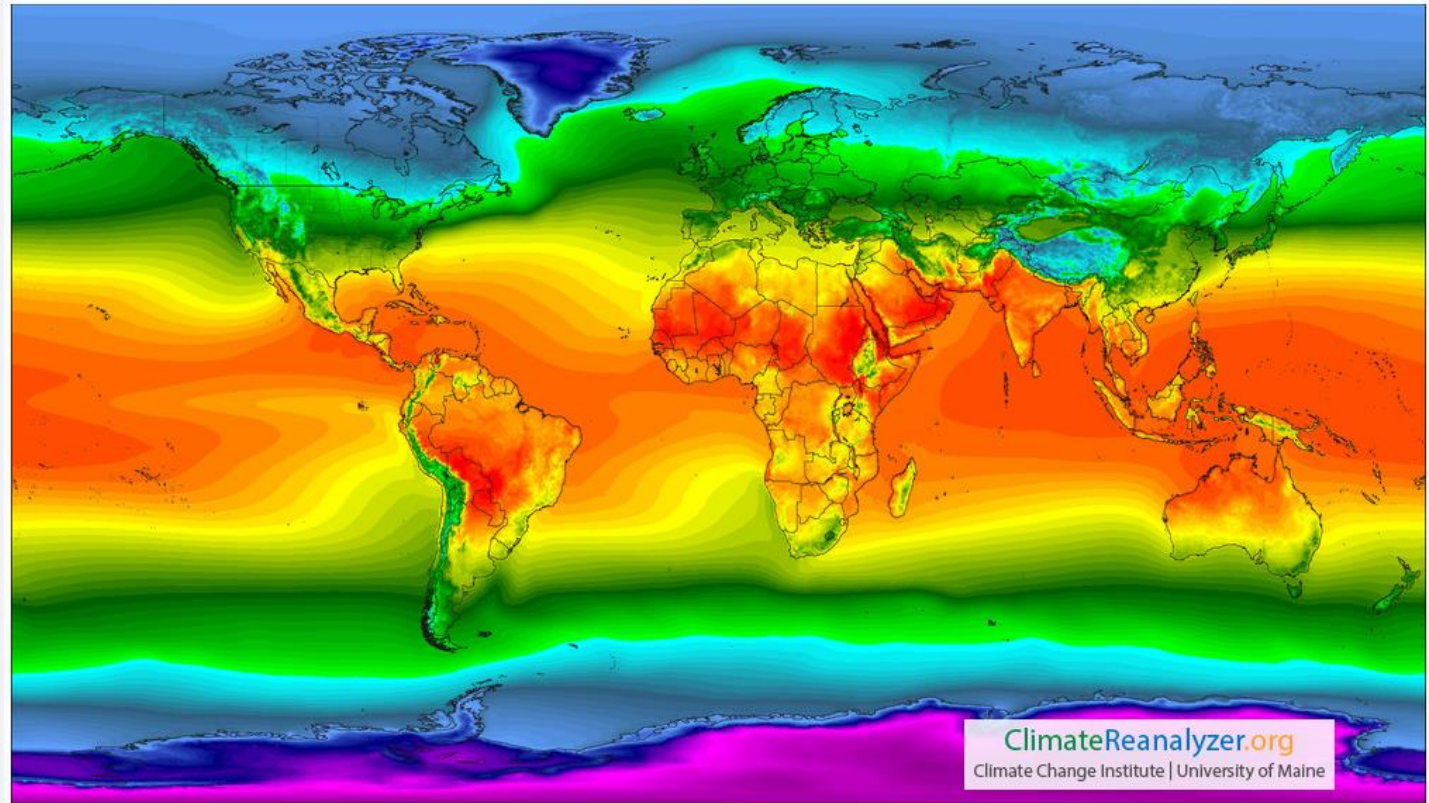
QUINTA 28° 19°

METEORED info


Global  $\Delta T = -1^{\circ}\text{C}$

83% Modern, 17% LGM

Annual Average



Environmental Change Model, Version 2015A



Fonte: ClimateReanalyzer (2023)

**ANEXO K -Dados globais (Little Ice Age, ca. 1850)**

**i-Cida**

Administrador

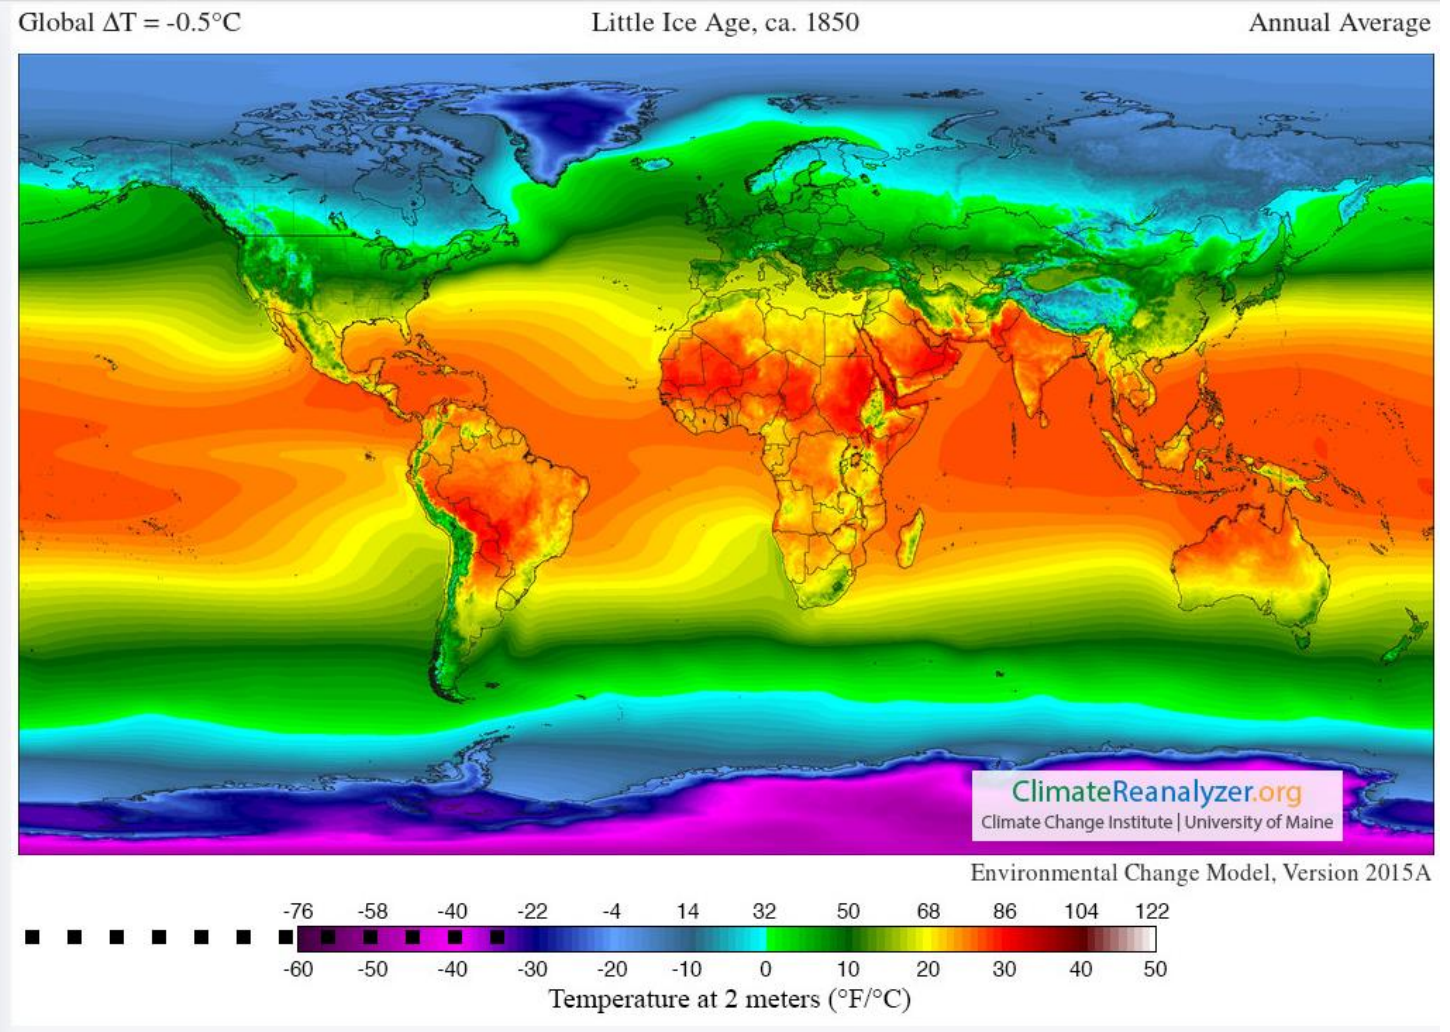
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

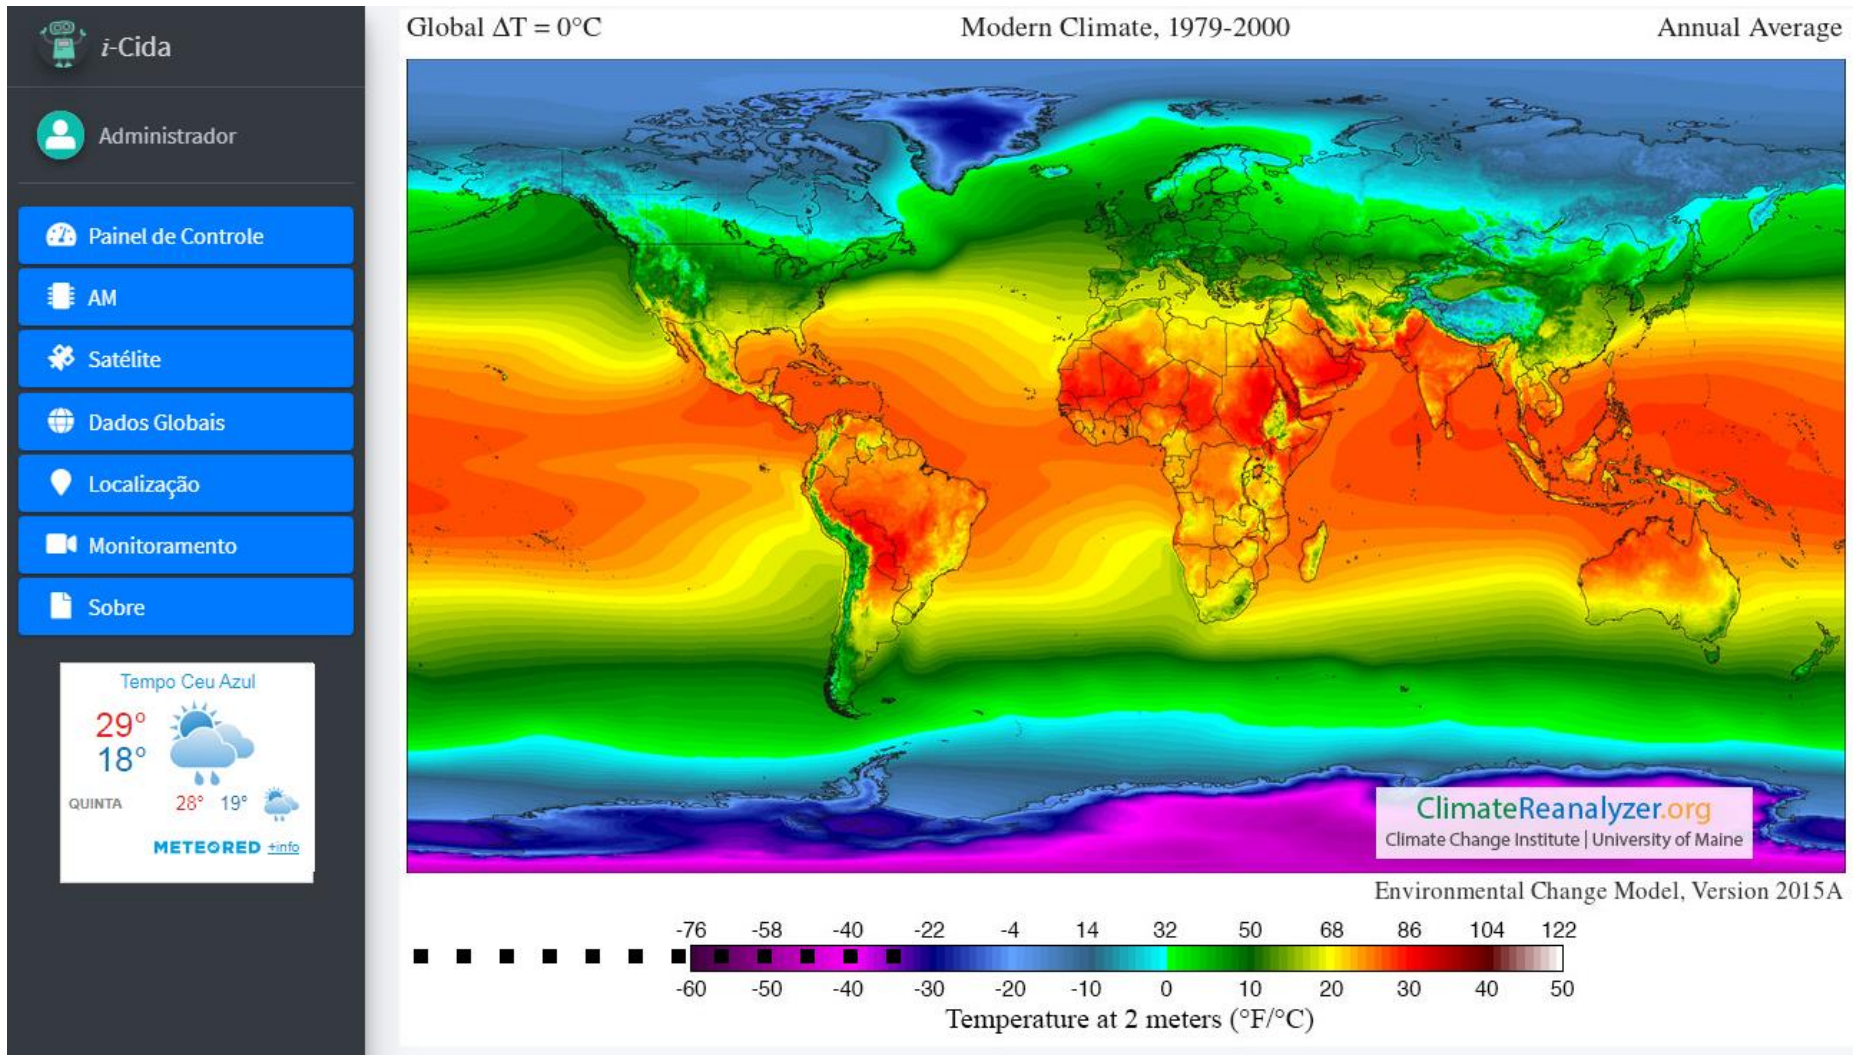
METEORED +info



Fonte: ClimateReanalyzer (2023)



**ANEXO L - Dados globais (ModernClimate, 1979-2000)**



Fonte: ClimateReanalyzer (2023)

**ANEXO M -Dados globais (IPCC RCP-8.5 2025)**

**i-Cida**

Administrador

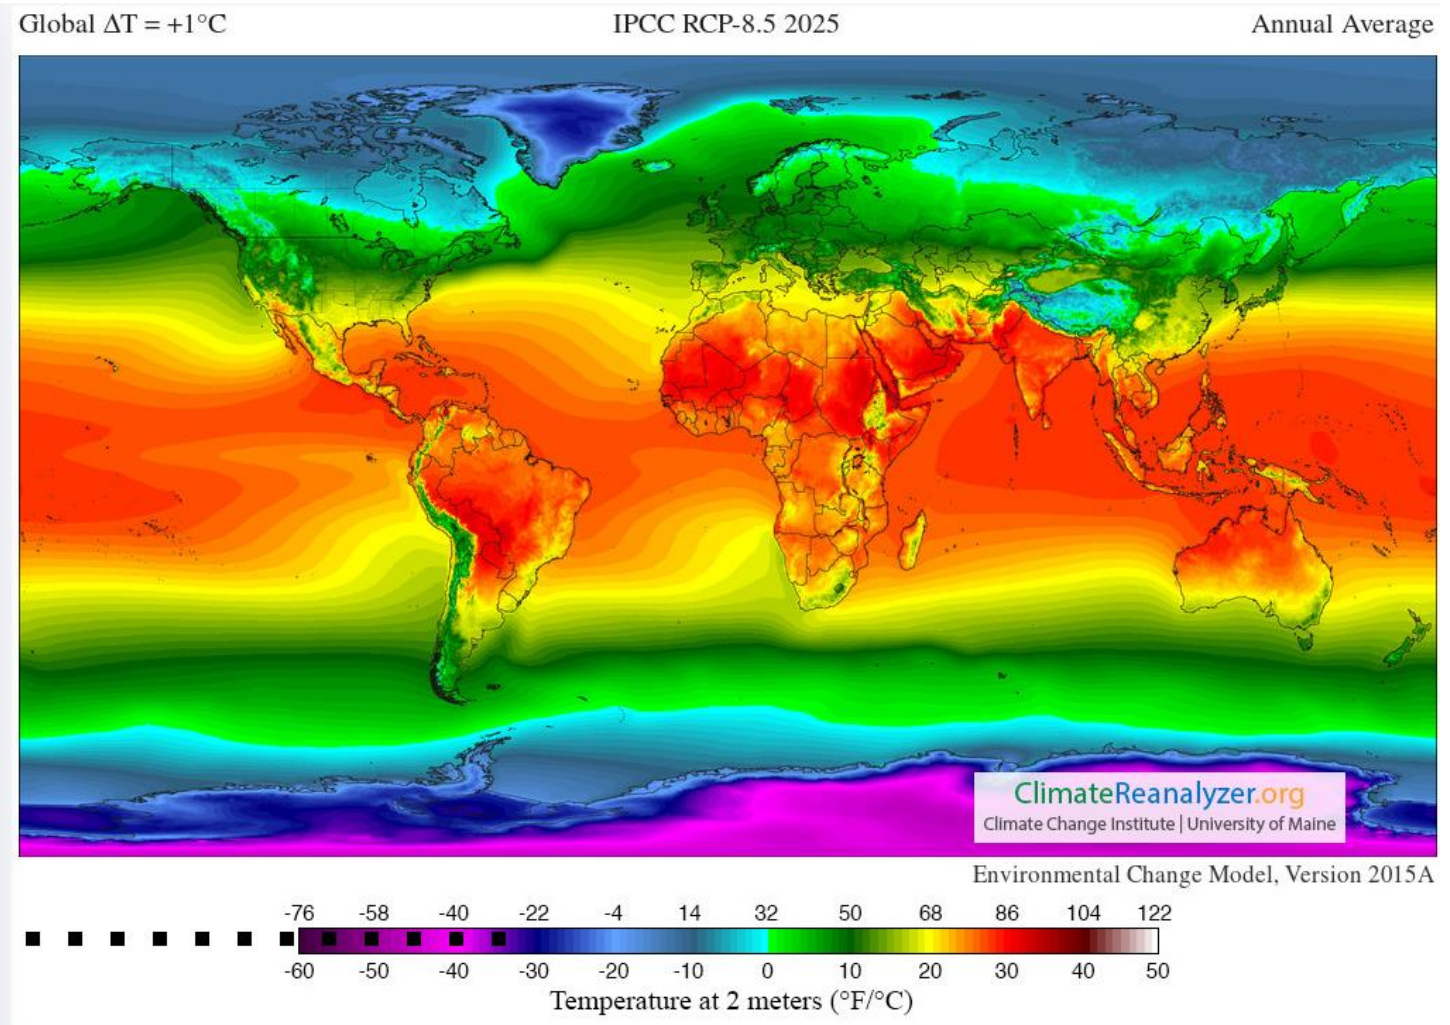
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

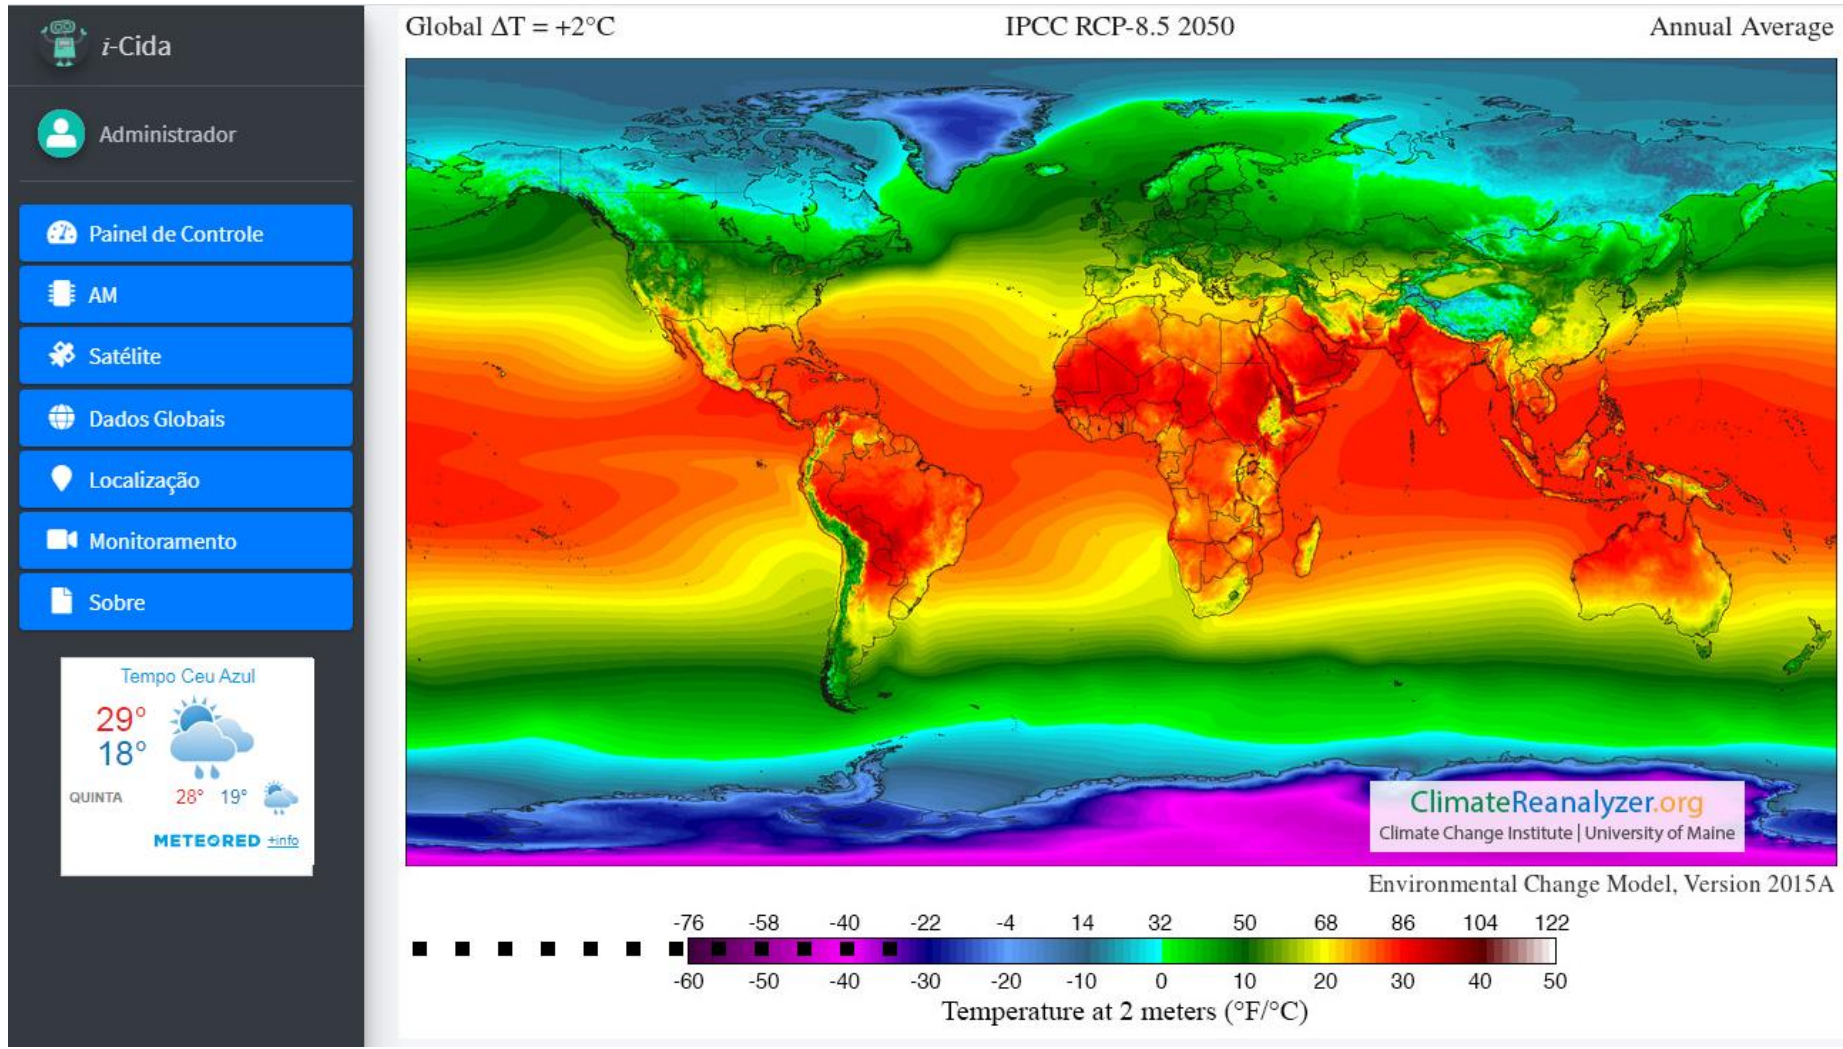
METEORED info



Fonte: ClimateReanalyzer (2023)


**ANEXO N - Dados globais (IPCC RCP-8.5 2050)**








Fonte: ClimateReanalyzer (2023)

**ANEXO O -Dados globais (IPCC RCP-8.5 2075)**

 i-Cida

 Administrador

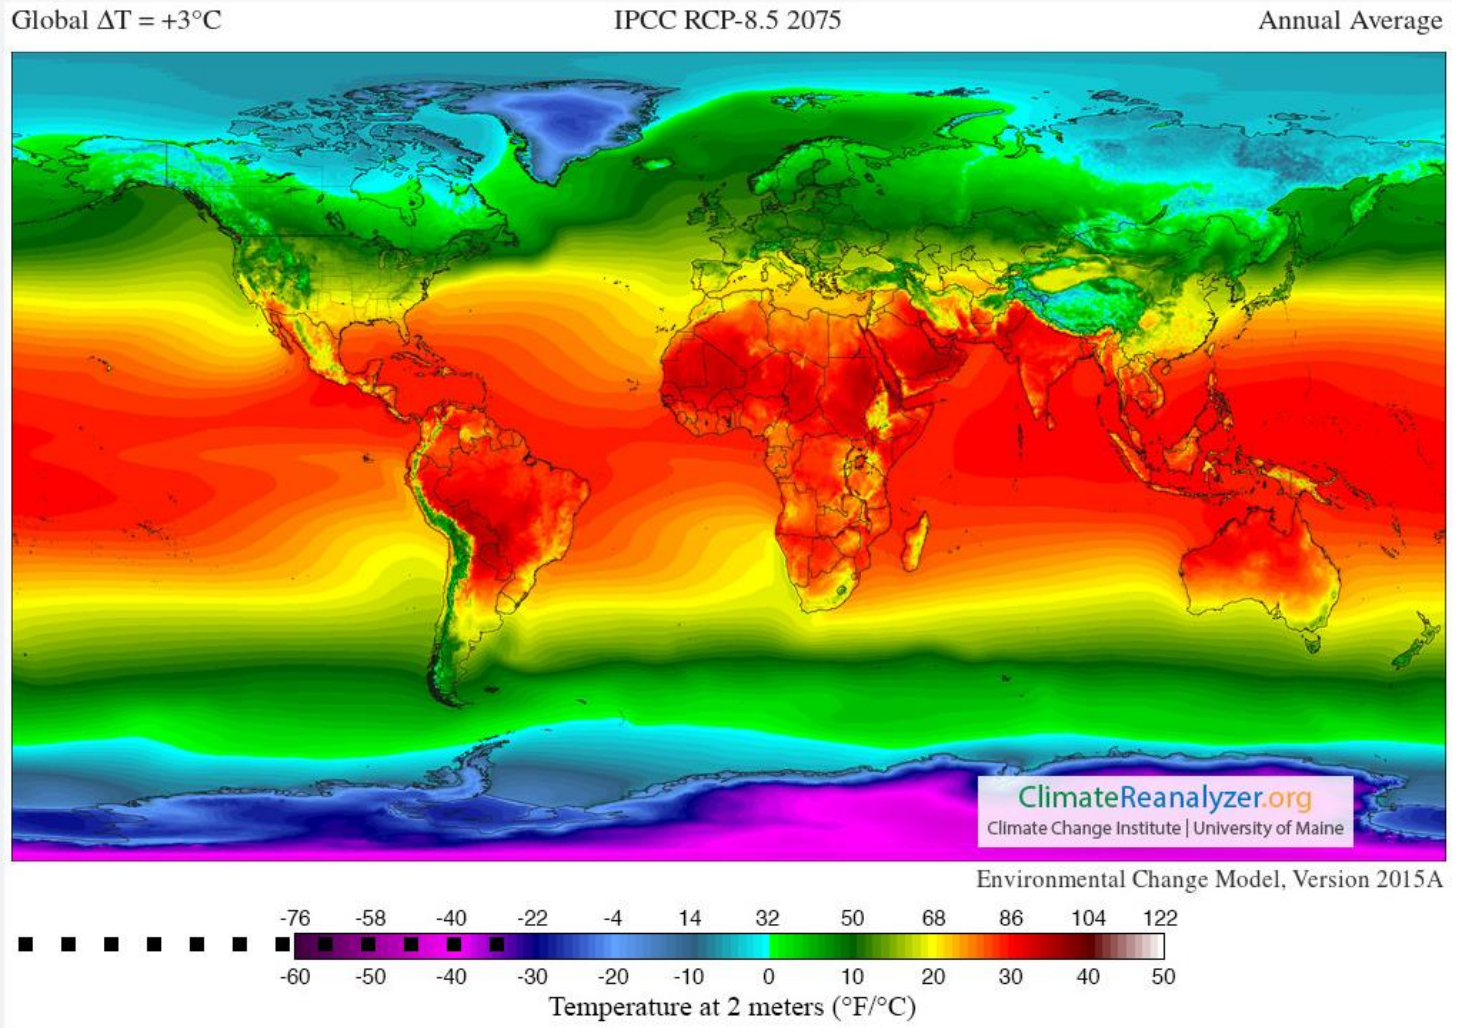
-  Painel de Controle
-  AM
-  Satélite
-  Dados Globais
-  Localização
-  Monitoramento
-  Sobre

Tempo Ceu Azul

29°  
18°

QUINTA 28° 19°

METEORED +info



Fonte: ClimateReanalyzer (2023)



**ANEXO P - Dados globais (IPCC RCP-8.5 2100)**

**i-Cida**

Administrador

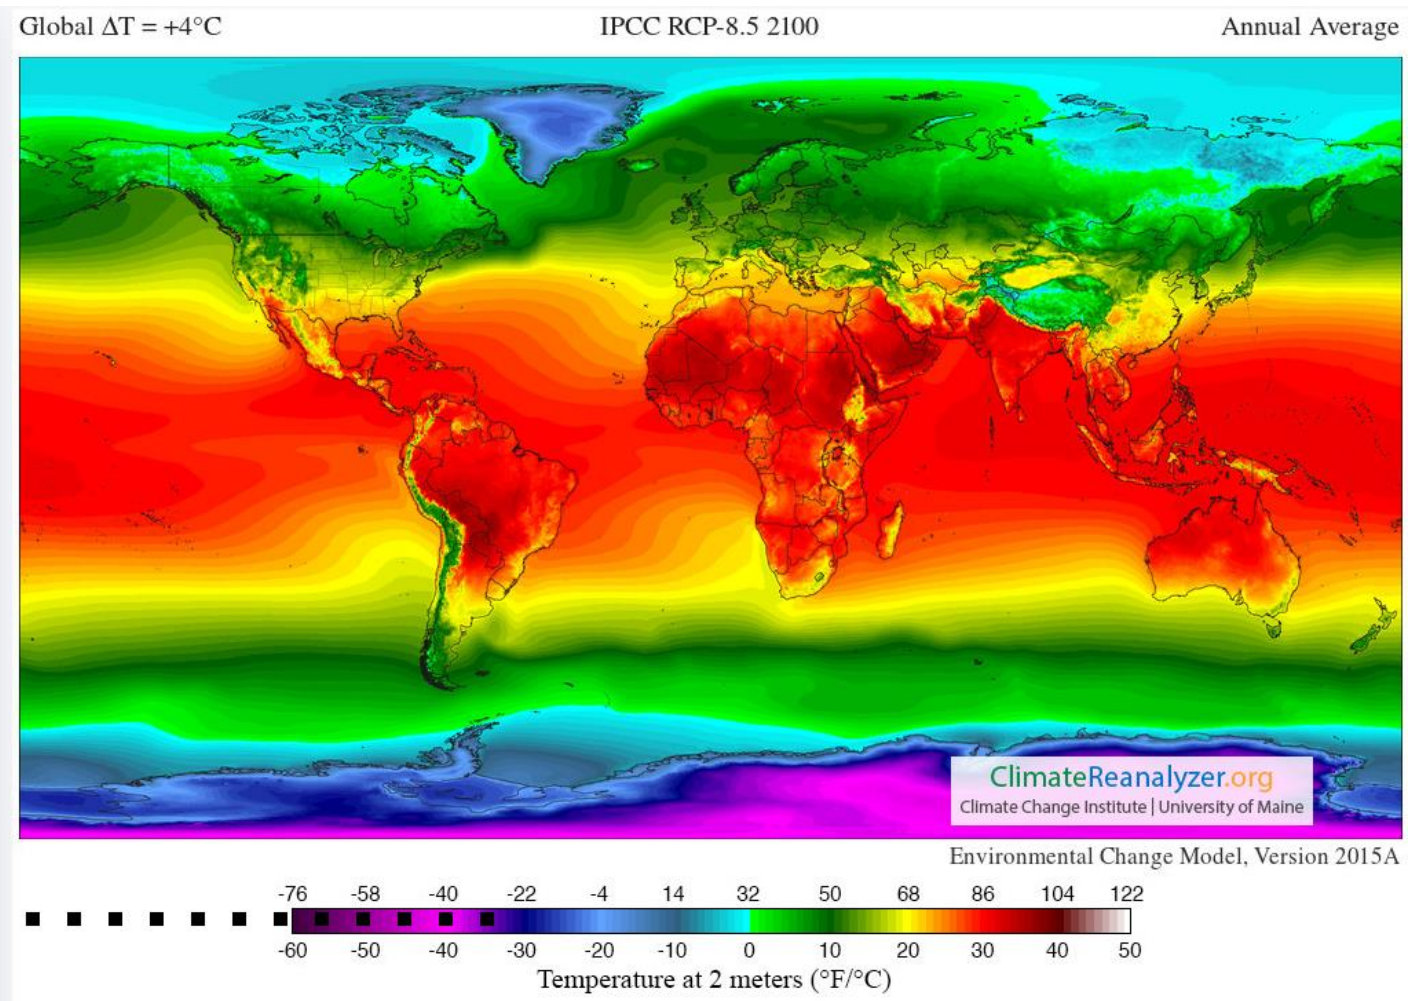
- Painel de Controle
- AM
- Satélite
- Dados Globais
- Localização
- Monitoramento
- Sobre

Tempo Ceu Azul

29°  
18°

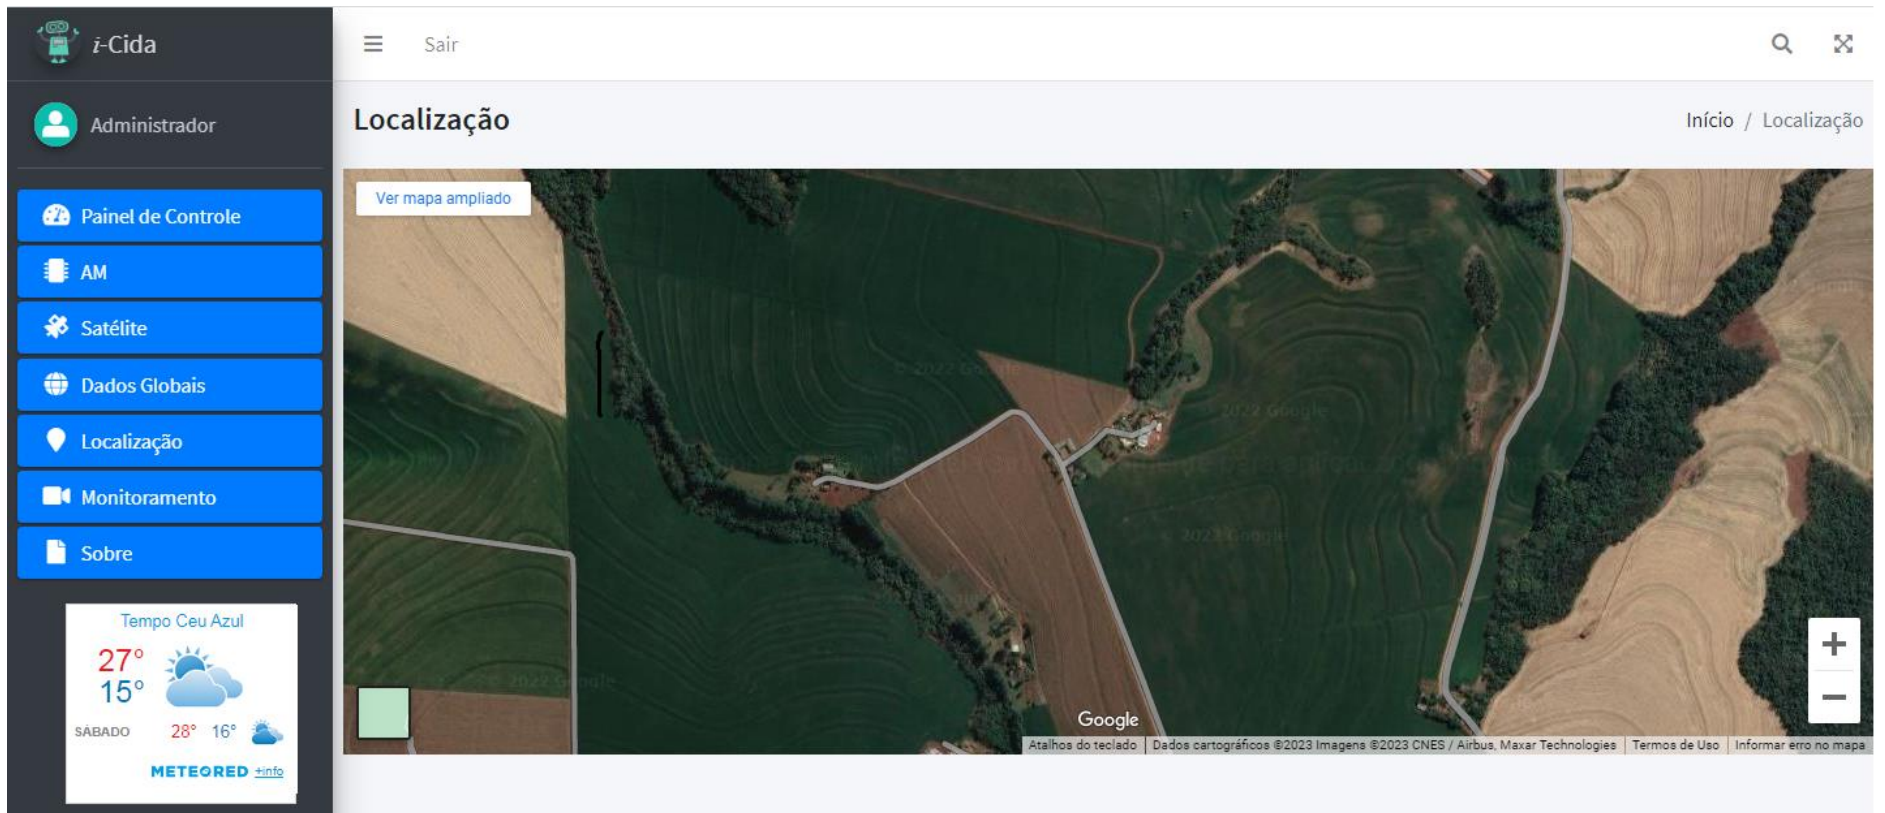
QUINTA 28° 19°

METEORED [sinfo](#)



Fonte: ClimateReanalyzer (2023)

**ANEXO Q - Tela localização**



Fonte: Google Maps (2023)

