



**CENTRO UNIVERSITÁRIO DE BRASÍLIA – UnICEUB**  
**PROGRAMA DE INICIAÇÃO CIENTÍFICA**

**THOMAS ALEXANDRE DA SILVA**

**ESTAÇÃO METEOROLÓGICA SUSTENTÁVEL APLICADA COM IOT E MACHINE  
LEARNING**

**BRASÍLIA**

**2021**



**THOMAS ALEXANDRE DA SILVA**

**ESTAÇÃO METEOROLÓGICA SUSTENTÁVEL APLICADA COM IOT E MACHINE  
LEARNING**

Relatório final de pesquisa de Iniciação Científica  
apresentado à Assessoria de Pós-Graduação e Pesquisa.

Orientação: Professor Me. William Roberto Malvezzi.

**BRASÍLIA**

**2021**

## RESUMO

Conhecimentos a respeito de históricos climáticos, bem como seus prognósticos, são utilizados por diversos segmentos acadêmicos e econômicos, dentre os quais se destacam ciências tais quais as biológicas, a agronomia, geografia, geologia, arquitetura, urbanismo e diversos outros, além de mercados tais quais o agronegócio. Outrossim, mudanças climáticas fomentam o monitoramento constante do clima e sua análise. Mediante a notória aplicação das ciências meteorológicas, cresce também o interesse por sua conexão em rede e a coleta dinâmica de suas variáveis, ajustando-se ao cenário emergente da IoT (*Internet of Things*) no século XXI.

Mediante o exposto, foi desenvolvida uma estação meteorológica sustentável, eletricamente autônoma, de baixo custo e integrada à IoT, contando, também, com a análise inteligente de dados em escopo local. A utilização de painéis solares por parte desta corrobora para a melhor mobilidade e praticidade da estação, não requisitando a extensão de fios no meio trabalhado. Adjunto a isto, tem-se a implementação de algoritmos de *Deep Learning* (Aprendizagem profunda) para previsões do tempo em 24 h com acurácia média de 90,9%, representando uma alternativa disruptiva para os padrões de prognósticos climáticos e transpondo o protótipo apresentado para aplicações tanto acadêmicas quanto de agronegócio.

Dentre as grandezas previstas pelo modelo apresentado, estão a temperatura do ar em bulbo seco e úmido, umidade relativa, pressão atmosférica, ponto de orvalho, índice de calor, índice de evaporação, índice pluviométrico e probabilidade de chuva. Além destas, grandezas como irradiância ultravioleta, iluminância ambiente, carga das baterias, velocidade eólica e direção dos ventos também são sensoriadas pela estação e dispostas no ambiente web do sistema desenvolvido.

**Palavras-chave:** Meteorologia, Deep Learning, IoT, Estação Meteorológica Automática, Previsão do Tempo.

## ABSTRACT

Knowledge about weather histories, as well as its forecasts, is used by various academic and economic segments, such as biology, agronomy, geography, geology, architecture, urbanism and several others, in addition to markets such as the agribusiness itself. Furthermore, climate changes encourage constant weather monitoring and analysis. Aware of the meteorological sciences notorious applications, interest also grows in its connection to the network and the dynamic collection of such variables, adjusting it to the emerging IoT (Internet of Things) scenario in the 21st century.

Based on such, a sustainable, electrically autonomous, low-cost, and integrated IoT meteorological station was developed, also relying on intelligent data analysis at a local scope. The use of solar panels by this prototype contributes to the station's better practicality, not requiring the extension of wires in the working environment. Nevertheless, Deep Learning algorithms were implemented for Weather forecasts in 24 h time length with an average accuracy of 90.9%, representing a disruptive alternative to patterns of climate prediction and transposing the presented prototype to both academic and agribusiness applications.

Among the variables predicted by the presented model, there are temperature in dry and wet bulbs, relative humidity, atmospheric pressure, dew point, heat index, evaporation index, rainfall index and probability of rain. In addition to these, variables such as ultraviolet irradiance, ambient illuminance, battery charge, wind speed and wind direction are also sensed by the station and displayed in the web environment of the developed system.

**Keywords:** Meteorology, Deep Learning, IoT, Automated Meteorological Station, Weather Forecast.

## AGRADECIMENTOS

A publicação deste documento só foi viável graças às contribuições de diversas pessoas envolvidas, dentre elas o meu pai, Marcos Antonio da Silva, que ajudou muito com equipamentos e experiência na parte de funilaria para a moldagem das peças metálicas que compõem o invólucro físico da estação. Além deste, destacam-se as discussões teóricas com meu primo, Arthur Araújo Carvalho (licenciando em Química) tanto em domínio físico, quanto estatístico.

Obrigado, também, aos professores William Malvezzi e Ivandro Ribeiro. O Me. Malvezzi apadrinhou este projeto e foi o primeiro a propor a utilização de Machine e Deep Learning para este contexto. Já o mestre Ivandro Ribeiro foi, em realidade, coautor da ideia inicial, me sugerindo trabalhar em um protótipo de estação meteorológica microcontrolada por volta de 2017. É necessário, pois, reconhecer sua contribuição temática e agradecer ao Me. Ivandro por ter sido minha maior inspiração para desenvolver pesquisas no ramo de sistemas embarcados e automação do agronegócio.

Por fim, agradeço a todos os que estiveram envolvidos no desenvolvimento prático e teórico deste projeto, bem como a todos os professores que contribuíram para minha carreira acadêmica e ao apoio que tive de vários amigos e familiares.

*Obrigado a todos!*

Thomas Alexandre da Silva

## CITAÇÃO

*"No matter where you go, We're all connected."*

(Iwakura Lain)

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO: .....</b>	<b>17</b>
2.1	Grandezas sensoriadas e estimadas .....	17
2.1.1	Sensores eletrônicos, eletromecânicos e seus modelos .....	17
2.1.2	Grandezas compostas e modelos estimativos: .....	22
2.2	Autonomia elétrica: .....	25
2.2.1	Placas solares e baterias: .....	25
2.2.2	Monitoramento de carga .....	26
2.3	Séries Temporais:.....	27
2.3.1	Métodos Estatísticos Cogitáveis .....	27
2.3.2	RNN e LSTM .....	28
<b>3</b>	<b>MÉTODO .....</b>	<b>31</b>
3.1	Implementação Eletromecânica do Projeto: .....	32
3.2	Geolocalização da estação prototipada .....	37
3.3	Pré-processamento dos dados .....	37
3.4	Implementação das Redes Neurais no <i>Backend</i> da Aplicação:.....	40
3.5	Implementação da Interface Gráfica. ....	43
<b>4</b>	<b>RESULTADO E DISCUSSÃO .....</b>	<b>48</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>50</b>
5.1	Reprodutibilidade do Protótipo e Recursos Materiais Necessários .....	50
5.2	Conclusões.....	51
5.3	Proposta de Trabalhos Futuros .....	51
	<b>BIBLIOGRAFIA.....</b>	<b>52</b>

## LISTA DE FIGURAS

Figura 1- Desenho técnico das dimensões físicas do DHT22. Unidades em milímetros. ....	17
Figura 2 - Foto e esquema métrico do sensor BMP180 e seus pinos.....	18
Figura 3 - Gráfico da Intensidade UV ( $mW/cm^2$ ) X Tensão de Saída (V).....	18
Figura 4 - Regressão quadrática em escala logarítmica entre a resistência e iluminância. ....	20
Figura 5 - Funcionamento de um pluviômetro bascular.....	21
Figura 6 - Anemômetro com biruta acoplada. ....	21
Figura 7 - Cofator p em função dos meses em diferentes latitudes .....	24
Figura 8 - Esquema de ligação entre placas solares, baterias e módulo recarregador .....	25
Figura 9 - Esquema elétrico do monitoramento de tensão na bateria .....	26
Figura 10 - Ilustração de uma RNN comum, uma empilhada e uma bidirecional. Cada retângulo expressa uma célula da rede e as setas representam o fluxo dos tensores.....	29
Figura 11 - Funcionamento interno de uma célula LSTM .....	30
Figura 12 - Visão panorâmica da estação e os pontos de sustentação do mastro. Hasteamento em P0 a 2,30 m de altura com hastes diagonais de 3,20 m abertas a 2,20 m do centro. ....	32
Figura 13 - Visão de seu módulo central em formato cúbico. Observam-se, em detalhes, os sensores indicados. Abrigo termo higrométrico a 1,90 m e corpo central a 1,50 m de altura. Dimensões do corpo: 10x16x16 cm.....	33
Figura 14 - Visão do anemômetro e da biruta. Altura de 4,56 m.....	33
Figura 15 - Visão da placa no corpo eletrônico central. Base do corpo a 1,4 m e ponto médio em 1,5 m de altura.....	34
Figura 16 - Irradiômetro UV e luxímetro encapsulado por tampa acrílico em cano PVC. Altura de 2,45 m.....	34
Figura 17 - Vista superior da placa universal soldada e os soquetes de seus periféricos, bem como resistores e capacitores necessários. ....	35
Figura 18 - Vista inferior da placa universal soldada .....	35
Figura 19 - Mapa de terreno que contém a estação trabalhada (azul) e a 001 (vermelho)....	37
Figura 20 - Gráficos de dispersão da umidade entre os dados obtidos (x) e a estação 001 (y). ....	38
Figura 21 - Gráficos de dispersão da temperatura entre os dados obtidos (x) e a estação 001 (y). ....	38
Figura 22 - Gráficos de dispersão da pressão entre os dados obtidos (x) e a estação 001 (y).38	38
Figura 23 - Velocidade e direção eólica na estação prototipada (y) em função da estação 001 do INMET (x). ....	39
Figura 24 - Sumário do modelo .....	41
Figura 25 – Página inicial do sistema logo após o login, com o histórico registrado dos últimos dias. ....	44
Figura 26 – Previsões na página inicial.....	44
Figura 27 - Painel de informações com os dados mais recentes para a janela temporal selecionada em “filtros”. Informações de 24/07/2021 às 23:59. ....	45
Figura 28 - Aba de grandezas primárias do sistema <i>web</i> .....	46



Figura 29 - Aba de grandezas compostas.....	46
Figura 30 - Aba de radio-iluminância exibindo a radiação global e a radiação UV. ....	47
Figura 31 - Tensão e porcentagem de carregamento das baterias.....	47
Figura 32 - A primeira tabela se refere à avaliação do modelo para temperatura, umidade, pressão e seus derivados. A segunda tabela apresenta os mesmos indicadores estatísticos, acrescido de uma acurácia categórica para probabilidade de chuva.....	48

### LISTA DE EQUAÇÕES

(1) .....	19
(2) .....	20
(3) .....	20
(4) .....	21
(5) .....	22
(6) .....	23
(7) .....	23
(8) .....	24
(9) .....	27
(10) .....	27
(11) .....	39
(12) .....	42

### LISTA DE TABELAS

Tabela 1 - Valores experimentais para a resistência do LDR (10 mm) e a iluminância medida. ....	19
Tabela 2 - Intervalos de tensão e suas representações em graus, pontos cardiais e colaterais. ....	22
Tabela 3 - Valores dos coeficientes para a função do índice de calor.....	23
Tabela 4 - Pinos utilizados pelo microcontrolador e suas funções .....	36
Tabela 5 - Correlações entre os dados colhidos com os do INMET para a estação 001. ....	39
Tabela 6 – Resultado das estatísticas de avaliação do modelo. ....	43
Tabela 7 - Tabela de materiais, unidades e preços estimados.....	50

## LISTA DE ABREVIATURAS E SIGLAS

ADAM – *Adaptive Moment Estimation*

ADC – *Analog Digital Converter*

API – *Application Programming Interface*

ARIMA – *Autoregressive Integrated Moving Average*

ARIMAX – *Autoregressive Integrated Moving Average With Exogenous Variables*

CPU – *Central Processing Unit*

DP – *Deep Learning*

EMA – *Estação Meteorológica Automática*

EMC – *Estação Meteorológica Convencional*

GND - *Ground*

GPU – *Graphical Processing Unit*

IA – *Inteligência Artificial*

IDE – *Integrated Development Environment*

INMET – *Instituto Nacional de Meteorologia*

IoT – *Internet of Things*

JSON – *JavaScript Object Notation*

LDR – *Light Dependent Resistor*

LSTM – *Long Short-Term Memory*

MAE – *Mean Average Error*

MCU – *Movimento Circular Uniforme*

ML – *Machine Learning*

MSE – *Mean Squared Error*

NADAM – Nesterov Momentum ADAM

RAM – *Random Access Memory*

RMSE – *Root-Mean-Square Deviation*

RNN – *Recurrent Neural Network*

SARIMAX – *Seasonal Autoregressive Integrated Moving Average With Exogenous Variables*

SMAPE – *Symmetric Mean Absolute Percentage Error*

vCPU – *Virtual Central Processing Unit*

## 1 INTRODUÇÃO

As EMA's (Estações Meteorológicas Automáticas) foram crescentemente utilizadas no meio agrário desde a década de 80, devido a melhorias no rendimento energético dos *data loggers* e das comunicações de computadores (SNYDER et al., 1996). Neste contexto, a agricultura constitui o setor econômico mais intimamente dependente das informações climáticas e suas análises (PEREIRA et al., 2002). Já no que tange o clima futuro, há uma tendência de aquecimento geral e intensificação de anomalias e eventos extremos, como aumento de ondas de calor, elevação da velocidade eólica, além do prolongamento de secas e afins (CGEE, 2013). Neste contexto, é de se esperar que cresçam, também, estudos acadêmicos para monitoramento das mudanças climáticas, abrindo-se interesse na área em termos de pesquisa. Ademais, estações meteorológicas são objeto de estudo e visita para diversos segmentos acadêmicos, desde o ensino básico até a pós-graduação em cursos tais como Geografia, Agronomia, Biologia, dentre outros (FREITAS, 2012).

De forma geral, projetos de pesquisa voltados a estações meteorológicas integradas à rede vêm ganhando especial atenção desde a virada do século. Este fenômeno se deve, também, à aparição de módulos *wireless* de baixo consumo elétrico e custo de produção, o que motivou suas aplicações fora do domínio industrial, transpondo-as ao agronegócio (ALBEROLA, 2007) e possibilitando o desenvolvimento da IoT neste meio. No contexto da Internet das Coisas em aplicações agrícolas, tem-se a autonomia energética como um desafio (COSTA et al., 2018). Nesta conjuntura, a energia solar foi explorada como base para um modelo de estações na Índia, com captação de dados tais quais umidade relativa do ar, temperatura, níveis pluviométricos e radiação solar (GOSH, 2013). Coerente a estes conceitos, expande-se sua relevância não apenas para a Internet, mas sobretudo para a Inteligência das Coisas, isto é, uma variante da IoT integrada a métodos de ML (*Machine Learning*) e DL (*Deep Learning*). O advento da IA (Inteligência Artificial) nas últimas décadas pareceu-se com a vasta diversidade de informações e tecnologias computacionais, motivando diversas pesquisas para explorar diferentes padrões hierárquicos no grande volume de dados meteorológicos disponíveis (SALMAN et al., 2015).

Compreendida como fomentadora da quarta revolução industrial (SCHWAB, 2016), a Internet das Coisas se apresenta capaz de executar novos níveis de controle, prever variáveis

meteorológicas e monitorar a qualidade de alimentos, expondo-se como um agente que pode aumentar drasticamente a produtividade e sustentabilidade agrária (SUNDMAEKER et al., 2016). Apesar das inovações apresentadas pela IoT, avalia-se que há muito o que evoluir, sobretudo no que se refere a armazenagem em nuvem, melhoria da conectividade, aperfeiçoamento dos sensores e maior autonomia elétrica dos aparelhos (COSTA et al., 2018).

Integrado à Internet das Coisas enquanto tecnologia disruptiva, encontra-se a análise de seus dados por IA's como um estudo crescente e de grande relevância. Neste domínio, estima-se que os avanços em ML carregam potencial para converter dados em previsões climáticas rápidas, precisas e detalhadas (BOUKABARA et al., 2019), além do que, algoritmos de árvore já foram utilizados no contexto de previsões meteorológicas (HASAN et al., 2016).

Em tal conjuntura, é de interesse público a democratização do acesso aos dados de microclima locais, tanto a nível de histórico, como de previsão. Além da utilização de fontes renováveis, faz-se mister a boa eficiência energética do *hardware* e sua implementação via Internet das Coisas, contribuindo para um novo paradigma tecnológico emergente no século XXI (SÔNEGO, 2016).

Através dos conceitos de IoT aplicados a este contexto, desenvolveu-se um sistema *web* capaz de fornecer informações gráficas do histórico captado para análise. Outrossim, foram executadas compilações e integrações de redes neurais para fins de prognósticos e meteogramas segundo um padrão emergente de climatologia computacional.

Vide os seguintes objetivos específicos propostos e igualmente cumpridos:

- Com base nas modelagens matemáticas, implementou-se o código C++ (no Arduino-IDE), dando início ao protótipo da estação.
- Modelou-se o banco de dados e o sistema *web* para, então, executar a conexão do circuito com a rede local. Esta, serviu de *gateway* para envio ao servidor de aplicação.
- Monitorou-se o consumo elétrico da estação, substituindo a alimentação vigente (via fonte de bancada) por baterias recarregáveis e placas fotovoltaicas.
- Encapsulou-se a estrutura para disposição externa a céu aberto, captando dados relevantes.
- Programou-se a IA com intuito de análise de dados e previsões climáticas. Das fontes que a treinaram, estão históricos públicos de estações do INMET (Instituto

Nacional de Meteorologia) no DF.

- Implementou-se no sistema *web*: gráficos de séries temporais referentes tanto a dados de históricos locais (captados pela estação) quanto dos prognósticos futuros.

## 2 REFERENCIAL TEÓRICO:

Nesta seção, serão tratados os referenciais teóricos para todos os domínios que compõe a produção de uma EMA, suas previsões, estimativas e tecnologias associadas.

A priori, será abordado o corpo eletrônico que compõe a estação, especificando seus sensores digitais, analógicos e seu microcontrolador, o que culmina, logo em seguida, nas especificações técnicas do corpo físico da estação. Por fim, elabora-se a exposição explicativa dos módulos de previsão meteorológica por métodos de ML e DL.


### 2.1 Grandezas sensorizadas e estimadas

#### 2.1.1 Sensores eletrônicos, eletromecânicos e seus modelos

O DHT22 é um sensor de temperatura e umidade de alta precisão e baixo custo. Sua margem de erro é de aproximados 0.1°C e 0.1% de umidade relativa, operando de -40 a 80°C.

Todos os dispositivos da série DHTXX respondem a um protocolo serial próprio, cuja complexidade do funcionamento em baixo nível pode ser encapsulado e abstraído por bibliotecas disponíveis no Arduino-IDE para ESP-32. Devido à natureza do protocolo e sua implementação em *software*, pode-se utilizar qualquer pino de *Input/Output* do microcontrolador, fornecendo um bom grau de liberdade em *hardware*.


**Figura 1-** Desenho técnico das dimensões físicas do DHT22. Unidades em milímetros.



**Fonte:** (Adaptado de AOSONG, 2021)

Em se tratando do sensoriamento de pressão atmosférica, o barômetro BMP180 (Figura 2) é renomado pelo seu tamanho reduzido, baixo custo e baixo consumo elétrico. Enquanto periférico, possui uma interface com protocolo I<sup>2</sup>C de fácil implementação. Sua corrente de funcionamento ideal é de aproximados 5  $\mu$ A, podendo ser reduzida para 0,1  $\mu$ A quando ocioso.

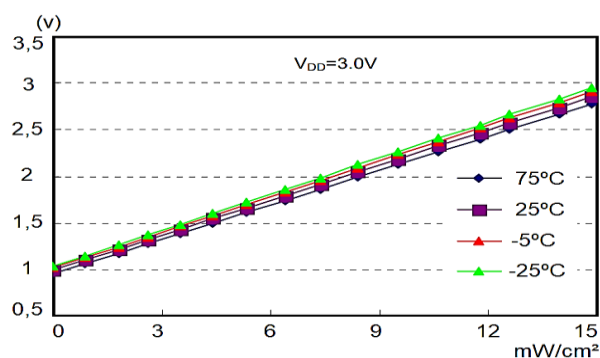
**Figura 2** - Foto e esquema métrico do sensor BMP180 e seus pinos



**Fonte:** (Adaptado de COMPONENTS101, 2018)

Já no que tange o monitoramento de iluminância e radiação solar, tem-se os componentes LDR e o sensor ML8611, respectivamente. O primeiro, como o nome sugere, é um resistor variável que produzirá diferentes níveis de tensão nos pinos de leitura analógica. Tendo-se auxílio de um luxímetro, verifica-se a relação resistência-iluminância e constrói-se o modelo matemático que será implementado durante a codificação do sistema embarcado. Já o ML8511 fornece um *output* analógico, cujo equivalente em tensão pode ser linearizado no intervalo de 1 a 3,5V (Figura 3).

**Figura 3** - Gráfico da Intensidade UV ( $\text{mW}/\text{cm}^2$ ) X Tensão de Saída (V)



**Fonte:** (Adaptado de LAPIS, 2013)

Supondo uma temperatura média de 25 °C e aplicando-se a inversa da função, tem-se a seguinte parametrização (1):

$$I_{UV} = \frac{15 \cdot V_s - 15}{1,83} \quad (1)$$

Nesta,  $V_s$  e  $I_{UV}$  representam, respectivamente, a tensão de saída e a intensidade da radiação ultravioleta. Devido à natureza linear do modelo, sua implementação em *firmware* não será computacionalmente custosa e não implicará possíveis perdas de performance no sistema embarcado.

Já no que se refere a iluminância ambiente, faz-se mister implementar uma correlação entre a resistência do LDR utilizado (10 mm), e as medições de um luxímetro calibrado. Desprende-se, daí, a seguinte tabela:

**Tabela 1** - Valores experimentais para a resistência do LDR (10 mm) e a iluminância medida.

LDR – 10 mm			LDR – 10 mm	
Resistência ( $\Omega$ )	Iluminância (lx)		LOG10[Res]	LOG10[Ilum]
56000	1	LOG10(X) →	4,748188027	0
18000	8		4,255272505	0,903089987
11200	16		4,049218023	1,204119983
7000	20		3,84509804	1,301029996
5000	30		3,698970004	1,477121255
2600	64		3,414973348	1,806179974
2250	122		3,352182518	2,086359831
1100	226		3,041392685	2,354108439
775	308		2,889301703	2,488550717
700	425		2,84509804	2,62838893
560	420		2,748188027	2,62324929
800	240		2,903089987	2,380211242
900	400		2,954242509	2,602059991
290	1450		2,462397998	3,161368002
250	1720		2,397940009	3,235528447
220	2330		2,342422681	3,367355921
160	4800		2,204119983	3,681241237
130	5800		2,113943352	3,763427994
93	13000		1,968482949	4,113943352
110	12000		2,041392685	4,079181246
130	7000		2,113943352	3,84509804
92	19000		1,963787827	4,278753601
60	20200		1,77815125	4,305351369
47	50000		1,672097858	4,698970004

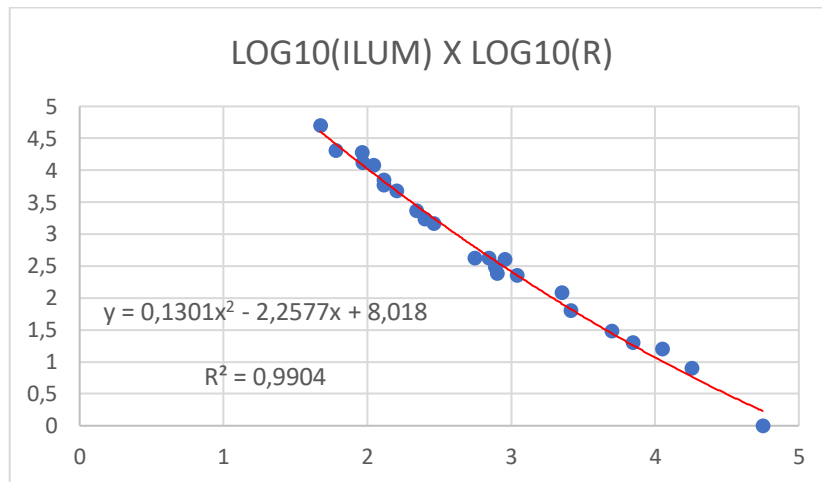
Fonte: (Autor, 2021).



E, dos valores em escala logarítmica, projeta-se o gráfico da Figura 4, podendo-se aplicar uma regressão polinomial de segundo grau conforme mostrado na equação (2), em que  $y$  representa o logaritmo na base 10 da iluminância e  $x$  o da resistência. Este modelo regressivo apresenta coeficiente de determinação  $R^2$  de 99.04%.

$$y = 0.1301x^2 - 2.2577x + 8.08 \quad (2)$$

**Figura 4** - Regressão quadrática em escala logarítmica entre a resistência e iluminância.



Fonte: (Autor, 2021).


Desenvolve-se a expressão (2), substituindo os logaritmos para obter a equação (3). Nesta,  $I(r)$  denota a iluminância (lux) e  $r$  a resistência ( $\Omega$ ).

$$I(r) = 10^{\{0.1301 [\log_{10}(r)]^2 - 2.2577 \log_{10}(r) + 8.08\}} \quad (3)$$

De tal forma, pôde-se desenvolver um luxímetro em baixo custo e boa precisão, utilizando apenas um LDR. A equação (3), desenvolvida pelo autor deste documento, será a base luximétrica da estação prototipada.

Quanto às análises pluviométricas, existem pluviômetros de báscula já prontos para serem implementados em sistemas microcontrolados. Vide a Figura 5.

**Figura 5** - Funcionamento de um pluviômetro bascular.



**Fonte:** (LUIZ et al., 2013)

Trabalhando-se com interrupções no processamento, contam-se os números de pulsos correspondentes às revoluções da bscula interna e calcula-se o volume d'gua precipitado.

O anemmetro (Figura 6), por sua vez, funciona como um contador de giros e tambm ativar interrupes externas. Contando-se o nmero de revolues por tempo, decorre-se a definio de frequncia ( $f$ ), e tendo-a, utilizam-se conceitos de MCU (Movimento Circular Uniforme) para estimar a velocidade tangencial do vento para o dado ciclo. Tendo-se o raio  $R$  como uma constante do sistema mecnico, aplica-se (4) para a obteno da velocidade elica mdia.

$$v_{elica} = 2. \pi. R. f \quad (4)$$

**Figura 6** - Anemmetro com biruta acoplada.



**Fonte:** (Autor, 2021).

A biruta acoplada (Figura 6) tambm configura um sensor eletromecnico em contexto de variveis elicas. Esta, por sua vez, gira um potencimetro e fornece um *output* analgico que pode ser convertido no ângulo de direo, variando entre 0,45,90,135,180,225,270 e 315 graus, que corresponde respectivamente s direes do vento em N, NE, E, SE, S, SO, O e NO. Vide a tabela seguinte:

**Tabela 2** - Intervalos de tensão e suas representações em graus, pontos cardiais e colaterais.

Mínimo (V)	Máximo (V)	Graus	Direção
0	0,27	315°	NO
0,27	0,32	270°	O
0,32	0,38	225°	SO
0,38	0,45	180°	S
0,45	0,57	135°	SE
0,57	0,75	90°	E
0,75	1,25	45°	NE
1,25	-	0°	N

Fonte: Autor.

## 2.1.2 Grandezas compostas e modelos estimativos:

### 2.1.2.1 Ponto de Orvalho

Uma vez obtidos os dados de temperatura e umidade relativa, tem-se como corolário imediato as definições de ponto de orvalho ( $T_{orv}$ ). Vide o modelo descrito por (5).

$$T_{orv}(RH\%, T) = 243,12 \cdot \left[ \frac{\ln\left(\frac{RH\%}{100\%}\right) + 6,757 \cdot 10^{-2} \cdot T}{17,62 - \ln\left(\frac{RH\%}{100\%}\right) - 6,757 \cdot 10^{-2} \cdot T} \right] \quad (5)$$

Fonte: (SENSIRION, 2008).

Nesta,  $RH\%$  representa a porcentagem de umidade relativa e ( $T$ ) denota a temperatura do ar (em bulbo seco). Compara-se, então, o resultado da expressão ( $T_{orv}$ ) com o parâmetro de entrada ( $T$ ). Para todo caso em que a temperatura de uma superfície for inferior a  $T_{orv}$ , definem-se as condições propícias para a formação de gotículas de orvalho sobre ela.

### 2.1.2.2 Temperatura de Bulbo Úmido

Esta medição denota a menor temperatura que o ar pode ser resfriado pela evaporação da água em uma pressão ambiente aproximadamente constante. Geralmente é medido por um termômetro tradicional de mercúrio com seu bulbo posto em um algodão ou peça de tecido úmida. De tal forma, é esperado que esteja presente majoritariamente em EMC's, pois é incomum que se encontrem data-loggers eletrônicos para sua medição, sendo majoritariamente feito por termógrafos de bulbo úmido ou anotação humana com base em um termômetro ou psicrômetro tradicional.

No entanto, é possível fazer estimativas de seu valor com base em parâmetros da umidade relativa e da temperatura do ar (bulbo seco). Vide o modelo matemático (STULL, 2011) a seguir (6).

$$T_{umido}(RH\%, T) = T \tan^{-1}(0.151977\sqrt{RH\% + 8.313659}) + \tan^{-1}(T + RH\%) - \tan^{-1}(RH\% - 1.676331) + 0.00391838 \tan^{-1}(0.023101RH\%) \sqrt{RH\%}^3 - 4.686035 \quad (6)$$

### 2.1.2.3 Índice de Calor

O Índice de calor é uma estimativa de temperatura aparente, relacionando a percepção humana desta. Tal grandeza combina a temperatura do ar e a umidade relativa, estando relacionada com a sensação de abafamento em localidades quentes com alta umidade, em que se tem dificuldade de secagem do suor e, portanto, de resfriamento do corpo.

Vide o modelo matemático (ANDERSON, 2013) a seguir (7), bem como os coeficientes explicitados pela tabela abaixo. Esta expressão parametriza T em graus Fahrenheit,  $RH\%$  em porcentagem e  $Ind(RH\%, T)$  como o índice de calor, igualmente calculado em Fahrenheit. Para tê-lo em célsius, uma conversão é necessária no *output* da parametrização apresentada.

$$Ind(RH\%, T) = c_1 + c_2T + c_3RH\% + c_4T + c_6RH\%^2 + c_7T^2RH\% + c_8TRH\%^2 + c_9T^2RH\%^2 \quad (7)$$

**Tabela 3** - Valores dos coeficientes para a função do índice de calor

Coeficiente	Valor
C1	-42,379
C2	2,04901523
C3	10,14333313
C4	-0,22475541
C5	-0,00683783
C6	-0,05471717
C7	0,00122874
C8	0,0008582
C9	-0,00000199

Fonte: (ANDERSON, 2013).

### 2.1.2.4 – Índice de Evaporação e Higrometria

Evaporômetros, ou atmômetros, são equipamentos hidrólogo-meteorológicos que medem a taxa de evaporação de uma superfície em contato com o ar atmosférico em pressão relativamente constante. Este tipo de equipamento possui diversas implementações, mas sua versão mais clássica consiste em um tanque d'água de boca larga que mede os valores inicial e final do nível hídrico. Como já é de se esperar, este tipo de equipamento consome bastante espaço e possui difícil implementação em sistemas automáticos, requisitando medidores de nível d'água e mais peças físicas a serem modeladas.

Para evitar as complicações de sua verificação direta, podem ser cogitados modelos matemáticos que estimem esta grandeza. Este é o caso da equação de Kharrufa (KHARRUFA, 1985). Tal parametrização leva como valores de entrada a temperatura do ar em bulbo seco e um cofator  $p$  referente à porcentagem diária média de horas diurnas do mês amostrado (relativa aos valores anuais). Vide, portanto, a representação deste modelo na expressão (8) em que  $T$  denota a temperatura média do ar ( $^{\circ}\text{C}$ ) e sua saída ( $IE$ ) é dada em milímetros por dia. O cofator  $p$  pode ser consultado pela tabela contida na Figura 7.

$$IE = 0.34 p T^{1.3} \quad (8)$$

Figura 7 - Cofator  $p$  em função dos meses em diferentes latitudes

Table 1  
Mean Daily Percentage ( $p$ ) of Annual Daytime Hours  
for Different Latitudes

Latitude	North	Jan	Feb	Mar	Apr	May	June	July	Aug	Sept	Oct	Nov	Dec
	South <sup>1/</sup>	July	Aug	Sept	Oct	Nov	Dec	Jan	Feb	Mar	Apr	May	June
60°		.15	.20	.26	.32	.38	.41	.40	.34	.28	.22	.17	.13
58		.16	.21	.26	.32	.37	.40	.39	.34	.28	.23	.18	.15
56		.17	.21	.26	.32	.36	.39	.38	.33	.28	.23	.18	.16
54		.18	.22	.26	.31	.36	.38	.37	.33	.28	.23	.19	.17
52		.19	.22	.27	.31	.35	.37	.36	.33	.28	.24	.20	.17
50		.19	.23	.27	.31	.34	.36	.35	.32	.28	.24	.20	.18
48		.20	.23	.27	.31	.34	.36	.35	.32	.28	.24	.21	.19
46		.20	.23	.27	.30	.34	.35	.34	.32	.28	.24	.21	.20
44		.21	.24	.27	.30	.33	.35	.34	.31	.28	.25	.22	.20
42		.21	.24	.27	.30	.33	.34	.33	.31	.28	.25	.22	.21
40		.22	.24	.27	.30	.32	.34	.33	.31	.28	.25	.22	.21
35		.23	.25	.27	.29	.31	.32	.32	.30	.28	.25	.23	.22
30		.24	.25	.27	.29	.31	.32	.31*	.30	.28	.26	.24	.23
25		.24	.26	.27	.29	.30	.31	.31	.29	.28	.26	.25	.24
20		.25	.26	.27	.28	.29	.30	.30	.29	.28	.26	.25	.25
15		.26	.26	.27	.28	.29	.29	.29	.28	.28	.27	.26	.25
10		.26	.27	.27	.28	.28	.29	.29	.28	.28	.27	.26	.26
5		.27	.27	.27	.28	.28	.28	.28	.28	.28	.27	.27	.27
0		.27	.27	.27	.27	.27	.27	.27	.27	.27	.27	.27	.27

<sup>1/</sup> Southern latitudes: apply 6 month difference as shown.


## 2.2 Autonomia elétrica:

### 2.2.1 Placas solares e baterias:

Conforme anteriormente exposto, a independência elétrica constitui um diferencial para projetos de IoT no agronegócio. Para tal, é necessária uma bateria de longa duração que mantenha a estação ligada por 12 h sem luz solar e painéis capazes de reabastecê-las completamente durante o período de irradiação solar, mesmo em dias nublados. O valor de 12 h foi escolhido tendo em vista latitudes de médio e baixo módulo, em que o dia e a noite configuram proporção temporal próxima a 1:1, mesmo durante solstícios. Este dado está, portanto, coerente com a realidade do centro-oeste brasileiro e com o Brasil de maneira geral.

Para atingir tal autonomia, foram utilizadas 4 células 18650 de 2.6 mAh e 3.7 V, junto a 4 painéis de 3.5 W/10 V e um módulo recarregador 5V-12 V a 9 V UPS. Vide (8).

**Figura 8** - Esquema de ligação entre placas solares, baterias e módulo recarregador



**Fonte:** (Adaptado de CASA DA ROBÓTICA, 2021).

Optou-se pelos painéis em paralelo para manter a tensão fixa em 10 V e quadruplicar a corrente. De tal forma, não se extrapola a tensão limite de entrada do módulo DC UPS e obtém-se maior velocidade de carga às células da bateria. Estas, por sua vez, também foram postas em paralelo para respeitar a diferença de potencial elétrico de sua conexão com o módulo e quadruplicar a capacidade em amperes-hora da bateria final. A saída fornecida é de


9 V, sendo esta posteriormente regulada a 5 V para alimentação da placa que contém o microcontrolador e seus periféricos.

Por fim, obtém-se desse esquema uma bateria total de 10400 mAh, capaz de manter um circuito simples - com consumo médio majorado entre 500 e 650 mA - por um período aproximado de 16 a 21 h até a descarga total. Observa-se que este intervalo é largamente superior às 12 h sem sol pretendidas, estando coerente com o objetivo almejado.

### 2.2.2 Monitoramento de carga

É interessante que tenhamos, no entanto, controle sobre a tensão na bateria e sua porcentagem de carregamento. O ESP-32 pode ser utilizado para medi-lo com um de seus pinos ADC. As células utilizadas no esquema supracitado apresentam uma tensão variante entre 3 V (0% carregadas) e 4.2 V (100% carregadas), mas esta última tensão é muito alta para as entradas analógicas do microcontrolador pretendido, haja vista seu limite de 3.3 V que não deve ser ultrapassado, tanto por questões de segurança (a fim de evitar a queima do processador) quanto de truncamento dos dados recebidos. De tal forma, resistores precisam ser acoplados para diminuir a tensão de entrada na porta pretendida. O monitoramento da bateria constitui, por conta desta condição, um diferencial em relação a todos os demais sinais analógicos recebidos e será detalhado logo abaixo.

**Figura 9** - Esquema elétrico do monitoramento de tensão na bateria



**Fonte:** (Autor, 2021).

Na Figura 9 observam-se os resistores  $R1$  e, pelos quais passam correntes  $I1$  e  $I2$ . O ponto A representa uma porta ADC do microcontrolador e o terminal B representa o ânodo da bateria - tal conexão é possível pois a referência de terra é a mesma para ambos. Sabe-se que nenhuma corrente flui em direção a A, obtendo-se que  $I1 = I2$ . Por cálculos de eletrodinâmica básicos, isola-se B e A em função das resistências na expressão (9).

$$B = \frac{A(R1+R2)}{R1}; A = \frac{BR1}{R1+R2}; \quad (9)$$

Deseja-se, ainda, que o potencial elétrico de  $A$  seja menor do que 3.3 V e  $B$  varie entre 3 e 4.2 V. O pior dos casos ocorre quando  $B$  é máximo, de onde se tira a seguinte inequação.

$$A = \frac{BR1}{R1+R2} \leq 3.3 \rightarrow \frac{4.2R1}{R1+R2} \leq 3.3 \rightarrow \frac{R1}{R2} \leq 3.6 \quad (10)$$

Pelo exposto em (10), tem-se que a relação entre  $R1$  e  $R2$  deve ser inferior a 3,6. Ora, tal exigência é respeitada para  $R1 = R2$ , e a igualdade de seus valores facilita a implementação eletrônica. Destarte, escolheu-se arbitrariamente valores de 330  $\Omega$  para esses resistores, resultando na equivalência final  $B = 2A$ .

## 2.3 Séries Temporais:

### 2.3.1 Métodos Estatísticos Cogitáveis

As séries temporais definem uma sequência de dados em que a ordem é relevante para a análise, podendo ser mono ou multivariada. Em ambos os casos, a variável de interesse preditivo é posta como um dado endógeno, isto é, criada pelo modelo, ao passo que todos os dados de entrada não definidos em saída são conceituados enquanto exógenos.

Para séries temporais contínuas, existem várias abordagens estatísticas que fornecem uma saída preditiva monovariada. Dentre estes, destaca-se o método de Alisamento Exponencial Triplo, também conhecido por Holt Winters. Tal modelo analisa fatores de nível, tendência e sazonalidade - descritos pelos seus respectivos hiper parâmetros  $\alpha$ ,  $\beta$  e  $\gamma$ . No entanto, este documento almeja previsões meteorológicas, e nenhum dado climático é totalmente independente um do outro – pelo contrário, existe uma forte correlação bidirecional entre a maioria de suas variáveis.

Ainda no domínio estatístico, tem-se o SARIMA como uma expansão sazonal para modelos autorregressivos integrados a média móveis (ARIMA). Neste, é possível acrescentar um vetor de dados exógenos – constituindo então o que se conhece por SARIMAX. Apesar deste ter sido inicialmente cogitado para os prognósticos climáticos deste documento, despreendem-se inúmeras adversidades de sua definição, tanto em precedência de dados quanto em custo computacional. O SARIMAX constitui um modelo sequencial que deve ser recompilado mediante novas evidências, necessitando de recálculo horário e um extremo



gasto do servidor *web* a cada requisição. Não é possível, portanto, a pré-compilação deste modelo para utilização futura a qualquer instante. Embora o mesmo impeditivo esteja presente em Holt-Winters, o modelo autorregressivo em questão possui uma complexidade potencialmente muito superior (a depender de seus hiper parâmetros) e tende a consumir mais tempo de processamento no servidor para obter uma acurácia minimamente razoável. Outrossim, o SARIMAX exige um vetor de previsões para as variáveis exógenas, isto é, não é capaz de prever uma saída múltipla com base em *inputs* múltiplos, mas prever uma variável endógena com auxílio de previsões das variáveis correlatas. A precedência de dados gera, em suma, o maior empecilho para sua utilização no contexto pretendido.

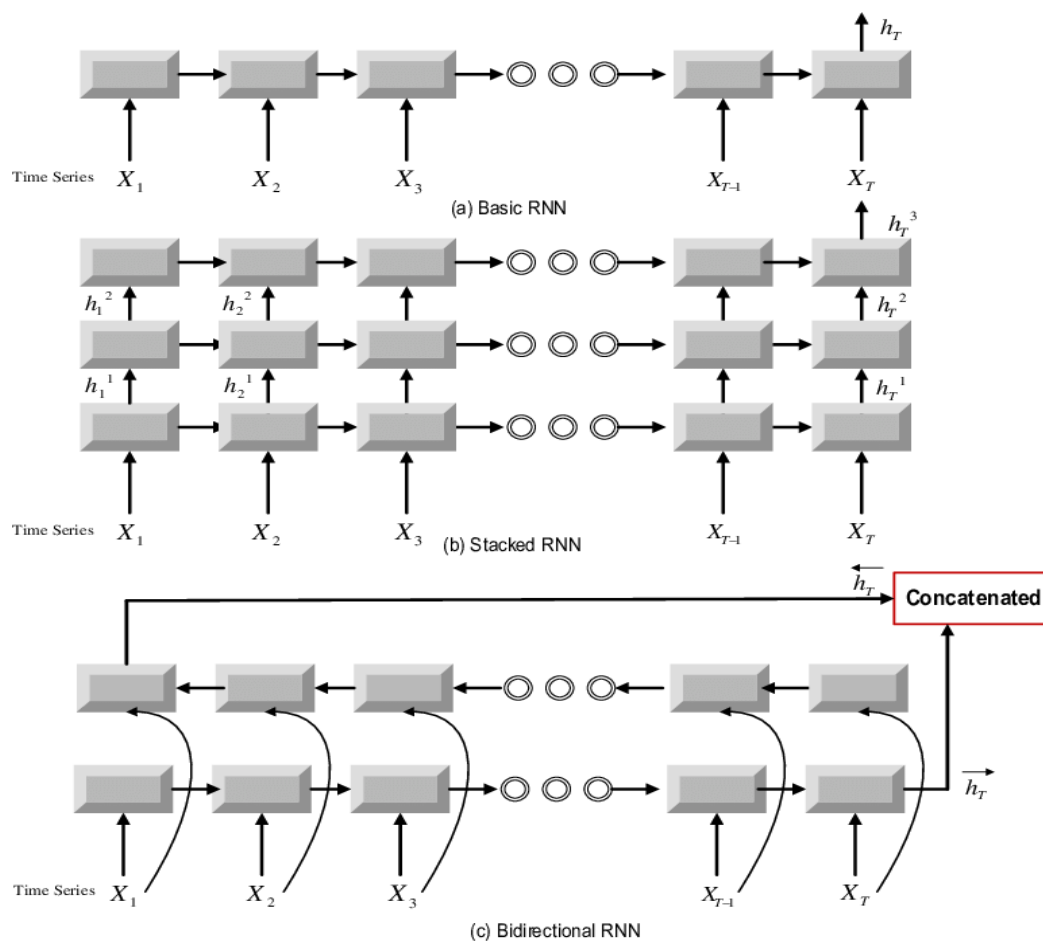
Desprende-se, daí, a necessidade de um modelo pré-compilável capaz de receber vários *inputs* para a previsão conjunta de vários *outputs* bidireccionalmente correlatos, estando estes compreendidos em uma janela temporal móvel de X horas. Para tal tipo de problema, redes neurais recorrentes (RNN's) costumam ser aplicadas.

### 2.3.2 RNN e LSTM

Em redes RNN, assim como qualquer outra rede neural, é necessário ter especial cuidado para evitar *overfitting* (sobreajuste) – processo no qual um modelo se encaixa perfeitamente na base de treinamento por memorizá-la, não por aprender seu comportamento, resultando em má performance quando posto contra a base de teste ou qualquer outra avaliação futura. Para tal, é comum a utilização de uma camada de *dropout*, que acrescenta impurezas aleatórias nos dados de entrada ou em seus tensores intermediários. Outrossim, tal rede também é repetida por diversas épocas durante seu treinamento, utilizando uma função de erro e um otimizador para convergir os pesos da rede até um encaixe ótimo. Dentre as opções mais populares, destacam-se o algoritmo ADAM (KINGMA *et al.*, 2015), e NADAM. O primeiro consiste em uma otimização de substituições para gradientes estocásticos, e o segundo em uma variação do primeiro com momento de Nesterov aplicado (DOZAT, 2016).

Estas redes podem ser implementadas de diferentes formas, sendo as mais comuns: seu modelo básico, o empilhamento de diversas camadas recorrentes, a implementação de uma camada recorrente em via dupla (bidireccional) e, ainda, a combinação do empilhamento com a bidireccionalidade supracitada. Vide uma ilustração destas arquiteturas na Figura 10.

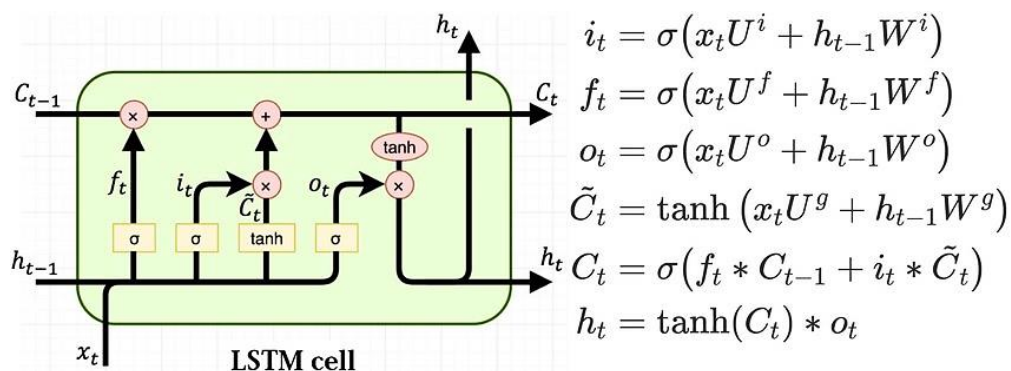
**Figura 10** - Ilustração de uma RNN comum, uma empilhada e uma bidirecional. Cada retângulo expressa uma célula da rede e as setas representam o fluxo dos tensores.



Fonte: (ZAO, Rui *et al.*, 2016)

Redes neurais recorrentes clássicas costumam sofrer um esmaecimento iterativo de seu gradiente, ocasionando uma perda de memória recente – o que é potencialmente indesejável para diversos problemas, inclusive o contexto climático pretendido. Mediante este inconveniente, a rede LSTM (*Long Short-Term Memory*) desponta como a principal filha das RNN's clássicas, herdando sua funcionalidade básica e, também, todas as arquiteturas previamente expostas. Cada célula desta rede implementa uma série de operadores sigmóides e tangentes hiperbólicas, conforme exposto na Figura 11, para evitar o esmaecimento relatado.

**Figura 11** - Funcionamento interno de uma célula LSTM



Fonte: (VARSAMOPOULOS *et al.*, 2018)

Como, em análises meteorológicas, existe uma bidirecionalidade entre as últimas horas observadas e as próximas ocorridas, bem como entre as variáveis em si, é possível imaginar uma aplicação igualmente bidirecional para este tipo de rede. Esta é possível através da biblioteca Tensorflow (ABADI *et al.*, 2015), para Python 3,0.

Com auxílio de bibliotecas, é possível encapsular a complexidade envolvida nos funcionamentos internos da rede LSTM. Estas atuam, portanto, como API entre o cerne matemático envolvido e o programador, sendo de especial importância para o desenvolvimento de DL neste projeto.

### 3 MÉTODO

O desenvolvimento do projeto proposto constitui uma pesquisa aplicada e qualitativa, executando a captação de dados numéricos para sua posterior interpretação em IA. Este estudo objetiva alterar a realidade acadêmica no ensino de climatologia e meteorologia, bem como a do agronegócio aplicada aos pequenos e médios produtores. A pesquisa foi subdividida, então, nos seguintes módulos:

**O primeiro módulo** consistiu em uma revisão bibliográfica da literatura científica vigente sobre o assunto, visando reforçar a base teórico-matemática que fundamenta a prática almejada. Foram utilizados livros, artigos científicos, documentações e os *datasheets* dos componentes – todos estes listados na bibliografia deste documento.

**O segundo módulo** consistiu na aplicação da teoria matemática unida à programação para o desenvolvimento de um código C/C++ compilado pela Arduino-IDE. O circuito foi implementado em protoboard para a captura de dados numéricos de teste. Este é, pois, o marco para o início da pesquisa quantitativa no projeto.

**O terceiro módulo** contém o desenvolvimento e modelagem do sistema *web* para armazenar os dados da estação e importar dados históricos do INMET.

**No quarto módulo**, transferiu-se o projeto para uma placa de circuito impresso e desenvolveu-se o encapsulamento para proteção de componentes sensíveis. Nesta etapa, já obtido um invólucro impermeável, a estação pôde ser exposta a céu aberto para captar dados reais.


**No quinto módulo**, aplicou-se os conhecimentos de estatística e IA ao sistema *web*, adicionando históricos climáticos, gráficos, histogramas e executando previsões climatológicas detalhadas. A análise qualitativa dos dados colhidos se deu neste ponto.

**No sexto módulo**, aplicaram-se painéis solares e baterias, substituindo a alimentação cabeada vigente.

### 3.1 Implementação Eletromecânica do Projeto:


Desenvolveu-se o invólucro físico da estação meteorológica que atua como abrigo para o corpo eletrônico central e seus sensores. Este foi feito em alumínio e pintado de branco para manter o albedo adequado (não interferindo na termometria). O corpo central consiste em uma caixa cúbica com fundo inferior vazado cuja face frontal funciona como porta vertical para manutenção da placa. Vide as imagens seguintes:

**Figura 12** - Visão panorâmica da estação e os pontos de sustentação do mastro. Hasteamento em P0 a 2,30 m de altura com hastes diagonais de 3,20 m abertas a 2,20 m do centro.



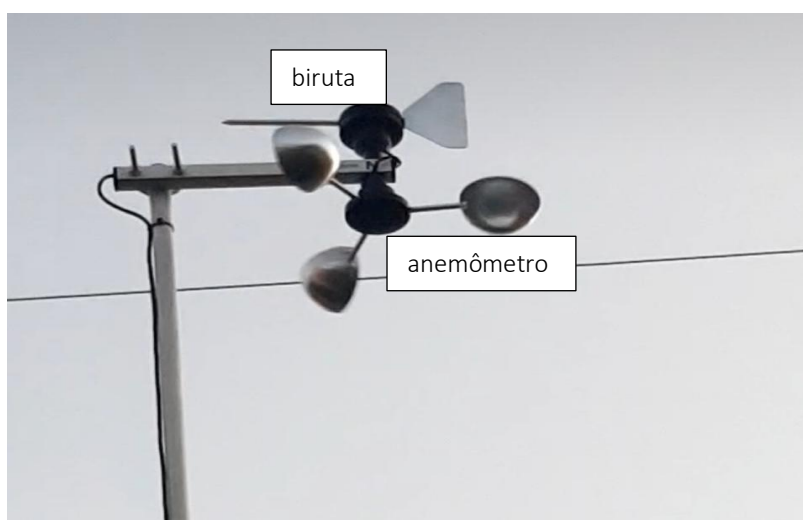
Fonte: (Autor, 2021).

**Figura 13** - Visão de seu módulo central em formato cúbico. Observam-se, em detalhes, os sensores indicados. Abrigo termo higrométrico a 1,90 m e corpo central a 1,50 m de altura. Dimensões do corpo: 10x16x16 cm.




Fonte: (Autor, 2021).

**Figura 14** - Visão do anemômetro e da biruta. Altura de 4,56 m.




Fonte: (Autor, 2021).

**Figura 15** - Visão da placa no corpo eletrônico central. Base do corpo a 1,4 m e ponto médio em 1,5 m de altura.



Fonte: (Autor, 2021).

**Figura 16** - Irradiômetro UV e luxímetro encapsulado por tampa acrílica em cano PVC. Altura de 2,45 m.




Fonte: (Autor, 2021).

Os periféricos foram ligados à placa a partir de cabos de internet e telefone reciclados e ressoldados. Estes tiveram uma ponta de seus terminais conectados aos pinos dos sensores e a outra moldada como entrada macho ou fêmea para seus respectivos soquetes na placa principal. Esta, por sua vez, se trata de uma placa universal soldada com soquetes de


periféricos, resistores, capacitores e a própria placa da fonte. Foram utilizados os sensores: DHT-22 (temperatura e umidade relativa), BMP-180 (pressão atmosférica), anemômetro com biruta (velocidade e direção do vento), pluviômetro bascular (índice pluviométrico) e o ML8511 (irradiômetro UV), bem como um LDR (iluminância) - todos conforme as modelagens previamente expostas na fundamentação teórica deste documento. Vide as seguintes imagens:

**Figura 17** - Vista superior da placa universal soldada e os soquetes de seus periféricos, bem como resistores e capacitores necessários.



Fonte: (Autor, 2021).

**Figura 18** - Vista inferior da placa universal soldada



Fonte: (Autor, 2021).



Codificou-se o microcontrolador por *pooling*, isto é, espera ocupada através de um loop principal com implementação de aguardo (1 segundo por iteração, neste caso). Concomitante a esta *thread*, interrupções de periféricos ocorrem para sensores tais quais o anemômetro e pluviômetro, alterando variáveis globais contadoras. Visando menor gasto de energia, a CPU teve sua frequência reduzida a 40 MHz durante o segundo esperado e, após este, restituída ao valor original de 240 MHz para a coleta de dados dos sensores e/ou envio de requisição até nova espera. A restituição foi necessária pois o sensor DHT-22 demonstrou mal funcionamento para menores frequências. Para evitar travamentos, ativou-se a alimentação do *Watchdog Timer* a cada loop, possuindo este um timeout de 180 segundos até a reinicialização automática. Ainda referente ao sistema embarcado, vide os pinos utilizados disponíveis na Tabela 4.

**Tabela 4** - Pinos utilizados pelo microcontrolador e suas funções

Pino	Natureza do dado/função
39	Interrupções do anemômetro
16	Dados seriais do DHT22 (termo-higrômetro)
17	Interrupções do pluviômetro
32	Analógico de direção eólica
33	Analógico de tensão na bateria
34	Analógico da iluminância pelo LDR
35	Analógico do Irradiômetro UV

**Fonte:** (Autor, 2021)

O ESP-32, por meio de seu módulo Wi-Fi, se conecta à rede doméstica e envia requisições à API construída (em seu end-point destinado a salvar as leituras climatológicas). O envio se dá de 10 em 10 minutos e, apenas no instante de envio, é que se liga o módulo Wi-Fi, desligando-o logo após este evento para menor consumo elétrico. A API de destino foi programada e desenvolvida pelo autor, tendo a responsabilidade de persistir os dados recebidos em um banco.

### 3.2 Geolocalização da estação prototipada

A estação proposta foi montada no Setor de Mansões de Taguatinga (Taguatinga Sul, DF) com as seguintes coordenadas: -15.853147, -48.065416, a cerca de 17 Km da estação 001, cujas coordenadas são -15.78944444, -47.92583332 (Setor Sudoeste, DF). Vide a Figura 19, que esboça a localização dos pontos supracitados.

**Figura 19** - Mapa de terreno que contém a estação trabalhada (azul) e a 001 (vermelho).

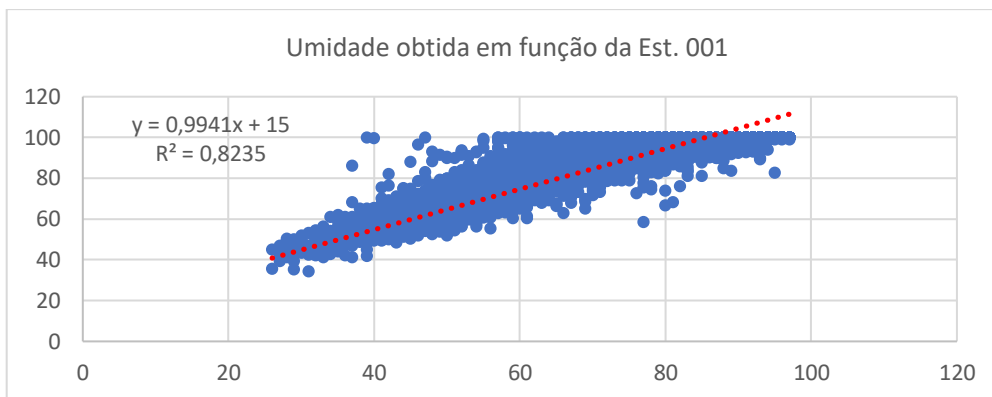


**Fonte** – (Adaptado de GOOGLE, INC. 2020)

### 3.3 Pré-processamento dos dados

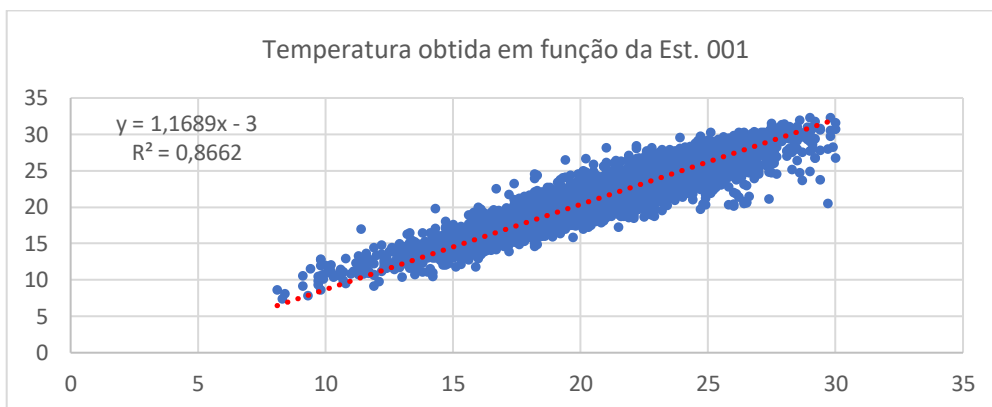
Sabe-se que diversos fatores afetam o microclima observado, desde a vegetação local até a presença de córregos ou diferenças de altitude. Tendo isso em vista, é necessário encontrar a correlação entre os dados de 001 e os colhidos na estação prototipada, pois, em posse de tal função, poder-se-ia aplicar a conversão nos dados históricos do INMET para estimar o que seria o histórico do microclima observado e, com base em estimativas tais, treinar uma rede neural para fins preditivos. Vide as regressões aplicadas nas imagens seguintes, bem como a correlação numérica entre os dados.

**Figura 20** - Gráficos de dispersão da umidade entre os dados obtidos (x) e a estação 001 (y).




Fonte: (Autor, 2021).

**Figura 21** - Gráficos de dispersão da temperatura entre os dados obtidos (x) e a estação 001 (y).



Fonte: (Autor, 2021).

**Figura 22** - Gráficos de dispersão da pressão entre os dados obtidos (x) e a estação 001 (y).



Fonte: (Autor, 2021).

Nota-se um valor de  $R^2$  superior a 82% para todos eles, tendo especial qualidade nos valores de pressão, em que  $R^2$  esteve acima de 96%. Esses indicadores reforçam a forte

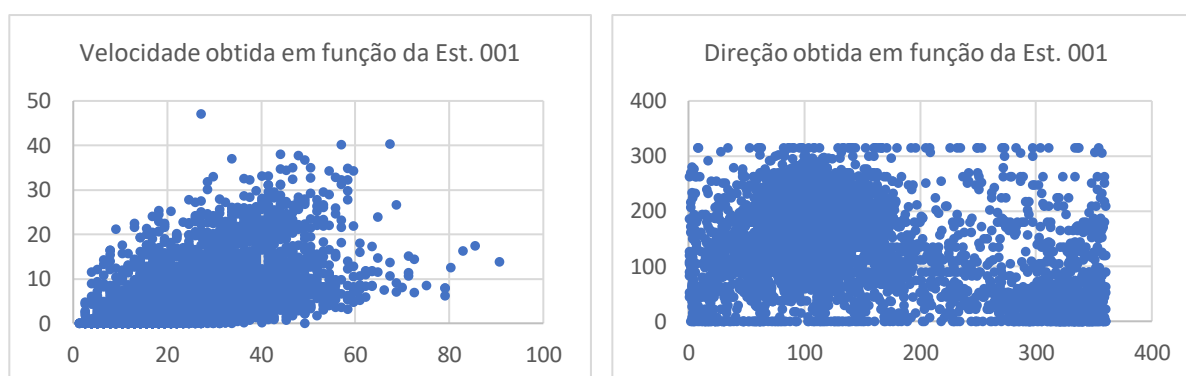
correlação linear entre os dados obtidos e os dados do INMET na estação 001. Desprende-se, das regressões aplicadas, o sistema de equações descrito pela expressão (11):

$$\begin{cases} T_{prot} = 1.1689T_{001} - 3 \\ RH\%_{0_{prot}} = 0.9941RH\%_{001} + 15 \\ P_{prot} = 0.9162P_{001} + 7092 \end{cases} \quad (11)$$

Fonte: (Autor, 2021).

Apesar destes bons resultados para as citadas variáveis, não foi observada uma correlação satisfatória para as duas grandezas eólicas trabalhadas: a velocidade e a direção dos ventos. Vide a grande dispersão de seus pontos nas figuras seguintes.

Figura 23 - Velocidade e direção eólica na estação prototipada (y) em função da estação 001 do INMET (x).



Fonte: Autor.

Para estas grandezas, supõe-se a interferência de construções adjacentes, pois a altura do mastro anemométrico de 4,56 m é potencialmente pequena para escapar da influência de obstáculos na dada localização. Destarte, observa-se grande espalhamento na dispersão.

Vide as correlações entre os dados e observe, também, os índices acima de 90% para temperatura, pressão e umidade (Tabela 5). Quanto à velocidade e à direção, devido aos resultados não satisfatórios, estes não serão utilizados para compor os algoritmos preditivos desejados, tanto em suas entradas.

**Tabela 5** - Correlações entre os dados colhidos com os do INMET para a estação 001.

Umidade	Pressão	Temperatura	Velocidade	Direção
0,9074469	0,9804378	0,930676898	0,521948646	-0,38237

Fonte: (Autor, 2021).

O segundo pré-processamento, por sua vez, consiste na transformação destes dados utilizando o algoritmo de *Robust Scaling*, da biblioteca Sklearn (PEDREGOSA, Fabian *et al*, 2011), para Python 3.0. Posteriormente, são geradas janelas temporais deslizantes na largura simétrica de 24 h com passos horários para o *input* e *output*. Tem-se, então, as bases para o aprendizado supervisionado de uma rede, cujos dados compõem um conjunto de pares: “últimas 24 h das X grandezas de entrada” e “24 h seguintes das Y grandezas de saída”.

Resta, agora, estipular quais as variáveis imputadas e quais aquelas a serem previstas. Definimos, portanto, que as janelas de *input* da rede possuem as seguintes grandezas: temperatura, umidade, pressão, delta de pressão (em passos unitários) e pluviometria (cumulativo horário). Os *outputs* contêm as mesmas grandezas, excetuando-se o delta de pressão e sendo acrescidos de uma categorização binária para a pluviometria. Esta última representará a probabilidade de chuva uma vez executadas as previsões. Tem-se, portanto, janelas multivariáveis de entrada com 5 parâmetros de largura e um conjunto de saídas contendo outros 5 (ambos aplicados a distribuições de 24 passos).

### 3.4 Implementação das Redes Neurais no *Backend* da Aplicação:

Codificou-se uma API em Python utilizando o Django Framework para o *backend* da aplicação. Esta concentra as responsabilidades de tratar as regras de negócio, gerenciar requisições, integrar com a base de dados e coordenar chamadas ao objeto do modelo preditivo. Esta aplicação está hospedada, junto com o banco de dados utilizado (PostgreSQL), em um servidor Ubuntu, com as seguintes especificações técnicas: 4 GB de memória RAM, 25 GB de disco e 2 vCPU's compartilhadas. A API responde a requisições via JSON, integrando-se a um *frontend web* desenvolvido em HTML5, CSS3 e JavaScript, com auxílio da biblioteca JQuery, C3-Chart e o framework reativo Vue-JS.

No que tange à rede neural utilizada para previsão, efetuou-se treinamento com dados horários do INMET para a estação 001 no intervalo de 06/01/2014 até 06/01/2021. O pré-processamento segue as etapas previamente expostas no tópico 3.3.

Ciente dos *inputs* e *outputs* desejados, codificou-se um modelo estruturado nas seguintes etapas, sendo estas referentes ao sumário da Figura 24:

1. Empilham-se quatro camadas LSTM bidirecionais, contendo 250 unidades cada uma.
2. Aplica-se um *dropout* regulado em 0,7 para evitar *overfitting*.
3. Por fim, uma camada de distribuição temporal em 24 passos. Esta encapsula uma camada densa de 5 unidades e faz o encaixe final dos tensores com a matriz-resposta.
4. Este conjunto forma a rede final do modelo, que foi treinado com a função de erro MSE por 400 épocas, utilizando o otimizador NADAM.

Figura 24 - Sumário do modelo

```

Model: "sequential"
Layer (type)                Output Shape                Param #
-----
bidirectional (Bidirectional (None, 24, 500))  512000
bidirectional_1 (Bidirection (None, 24, 500))  1502000
bidirectional_2 (Bidirection (None, 24, 500))  1502000
bidirectional_3 (Bidirection (None, 24, 500))  1502000
dropout (Dropout)           (None, 24, 500)           0
time_distributed (TimeDistri (None, 24, 5)  2505
-----
Total params: 5,020,505
Trainable params: 5,020,505
Non-trainable params: 0

```

Fonte: (Autor, 2021).

Obtendo-se as saídas de temperatura, umidade, pressão, pluviometria e probabilidade de chuva (todos das próximas 24 h), aplica-se um pós-processamento simples para a obtenção do ponto de orvalho, temperatura de bulbo úmido, índice de calor e índice de evaporação. Vide as equações (5), (6), (7) e (8) para recapitular as composições de tal processo.

O modelo em questão foi treinado em uma GPU GeForce GTX 1060 por cerca de 12 horas e o resultado deste treinamento foi armazenado em um arquivo de pesos (extensão “.h”) e um JSON com a estrutura da rede. A compilação utilizou a biblioteca Tensorflow (ABADI *et al*, 2015) para computar as operações de DL, além de importar os módulos NumPy (HARRIS *et al.*, 2020) e SkLearn (PEDREGOSA, Fabian *et al*, 2011) durante o pré e pós-processamento.

Outrossim, guardou-se os transformadores de *Robust Scaling*, visto que serão utilizados para operar as entradas futuras referentes às previsões e que é sumariamente necessário manter a mesma transformação de escalas utilizada durante o treinamento. Em posse destes,

os arquivos foram previamente abertos e carregados na memória do servidor. O arquivo de pesos e o JSON estrutural geraram uma pré-compilação do modelo completamente utilizável para rápido acesso em RAM. Tais dados, junto aos *scalers*, operam como constantes globais na aplicação Django do *backend*. Ao evitar a abertura dos arquivos em tempo de requisição das previsões, evitou-se também a competição de *threads* pelo recurso em disco e a latência de acesso. Requisições de prognósticos que demoravam cerca de 25s no servidor demoram, agora, entre 10 e 12s. Outrossim, com tal implementação, tem-se maior suporte para alto tráfego e chamadas simultâneas a este *endpoint* na API.

As estatísticas utilizadas para avaliação do modelo constam na expressão (12), onde  $\hat{x}_i$  denota o valor previsto para a  $i$ -ésima iteração e  $x_i$  o valor real ocorrido. Já no que se refere ao coeficiente de determinação  $R^2$ , tem-se a concepção de uma distribuição cartesiana dos pontos previstos e os ocorridos. Nesta,  $\hat{y}_i$  representa o valor no eixo Y para a previsão, e  $y_i$  o seu valor real. O termo  $\bar{y}$ , por sua vez, denota a média dos pontos neste mesmo eixo. Por fim, para a acurácia categórica, o valor  $t_p$  faz referência ao número de verdadeiros positivos, ao passo que  $f_p$  faz alusão ao de falsos positivos. O modelo foi avaliado entre 07/01/2021 e 24/07/2021, podendo ser verificado pelas performances dispostas na Tabela 6.

$$\begin{aligned}
 \left. \begin{aligned}
 &MAE = \frac{\sum_{i=1}^n |\hat{x}_i - x_i|}{n} \\
 &RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \\
 &SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{x}_i - x_i|}{\left(\frac{\hat{x}_i + x_i}{2}\right)} \\
 &R^2 = 100\% - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &Acurácia_{contínua} = 100\% - SMAPE \\
 &Acurácia_{categórica} = \frac{t_p}{t_p + f_p}
 \end{aligned} \right\} \text{Estat}_{aval} = \quad (12)
 \end{aligned}$$

**Tabela 6** – Resultado das estatísticas de avaliação do modelo.

	MAE	RMSE	R <sup>2</sup>	Acurácia contínua	Acurácia categórica
Temperatura (°C)	1.5 °C	2.05 °C	81.37 %	92.97 %	-
Umidade (%)	6.24 %	9.17 %	83.08 %	90.91 %	-
Pressão (hPa)	0.68 hPa	0.9 hPa	85.05 %	99.92 %	-
Índice de calor (°C)	1.8 °C	2.58 °C	77.11 %	91.91 %	-
Ponto de orvalho (°C)	1.44 °C	1.9 °C	82.24 %	90.49 %	-
Temp. de bulbo úmido (°C)	1.15 °C	1.5 °C	80.77 %	93.83 %	-
Índice pluviométrico diário (mm)	3.49 mm	9.4 mm	-8.21 %	39.92%	72.69%
Probabilidade de chuva diária (%)	-	-	-	-	77.13%

Média das acurácias (contínuas e categóricas)	90,91 %
---	---------

Fonte: (Autor, 2021).

Observe a boa performance da maioria dos dados contínuos, que se mantiveram acima de 90% em sua acurácia percentual, com coeficiente de determinação entre 77 e 86%. A única exceção para este foi a análise contínua da pluviometria (cumulação diária), que exibiu R<sup>2</sup> negativo e acurácia contínua de aproximados 40%. No entanto, esta mesma grandeza prevista demonstrou acurácia categórica binária (“chuva” ou “não chuva”, neste caso) de 72%, ligeiramente inferior aos 77% performados pela grandeza associada de “probabilidade de chuva”. De tal forma, desprende-se que a maioria das variáveis demonstram boa precisão e, embora a cumulação milimétrica de pluviometria não esteja tão fiel aos dados reais, esta exibe boa performance para a definição binária de sua grandeza.

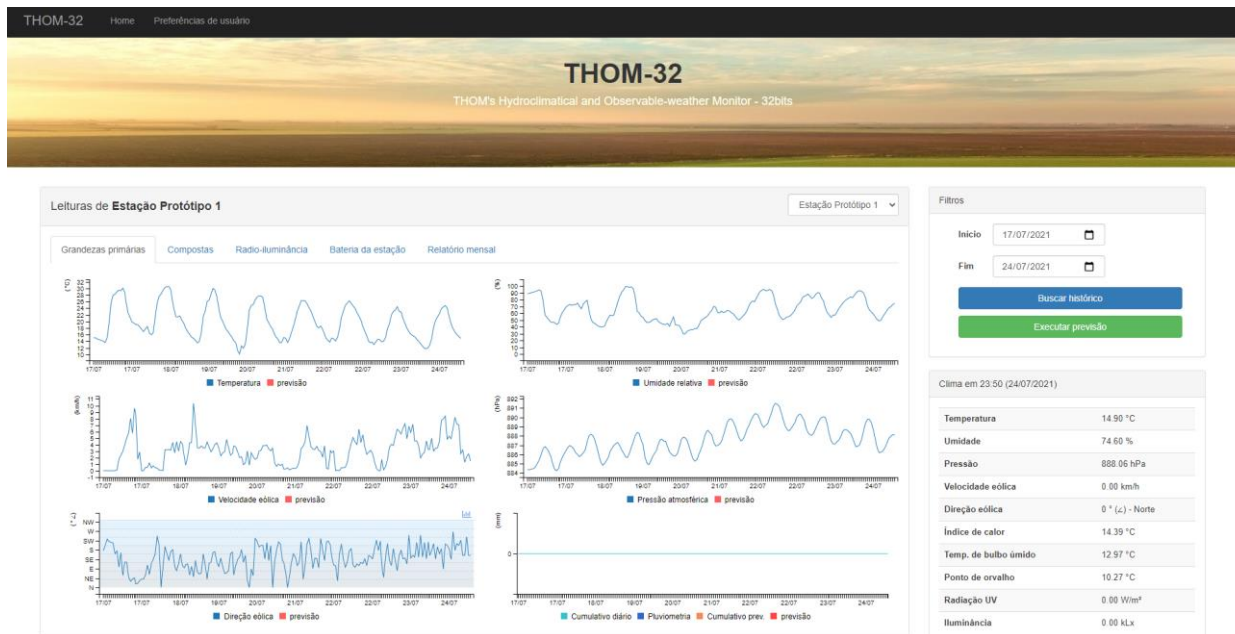
### 3.5 Implementação da Interface Gráfica.

Adentrando-se na interface gráfica do sistema, o painel da página principal foi dividido nas seguintes abas: Grandezas primárias (possuem sensor próprio); compostas (retorno de funções parametrizadas por entradas de dados primários); radio-iluminância (referentes à irradiação solar e iluminância ambiente); e Relatório de precisão (acurácia do modelo). Filtros para seleção de períodos a serem exibidos e analisados estão disponíveis no canto superior direito (Figura 25), selecionando estes qualquer intervalo contido no histórico de leituras colhidas (de 06/01/2021 até a presente data). Ainda na interface *web*, deu-se o nome de THOM-32 ao sistema, sendo este um acrônimo recursivo para *THOM’s Hydroclimatical and Obsearvable weather Monitor – 32 bits* (Monitor de clima observável e climatologia de THOM).

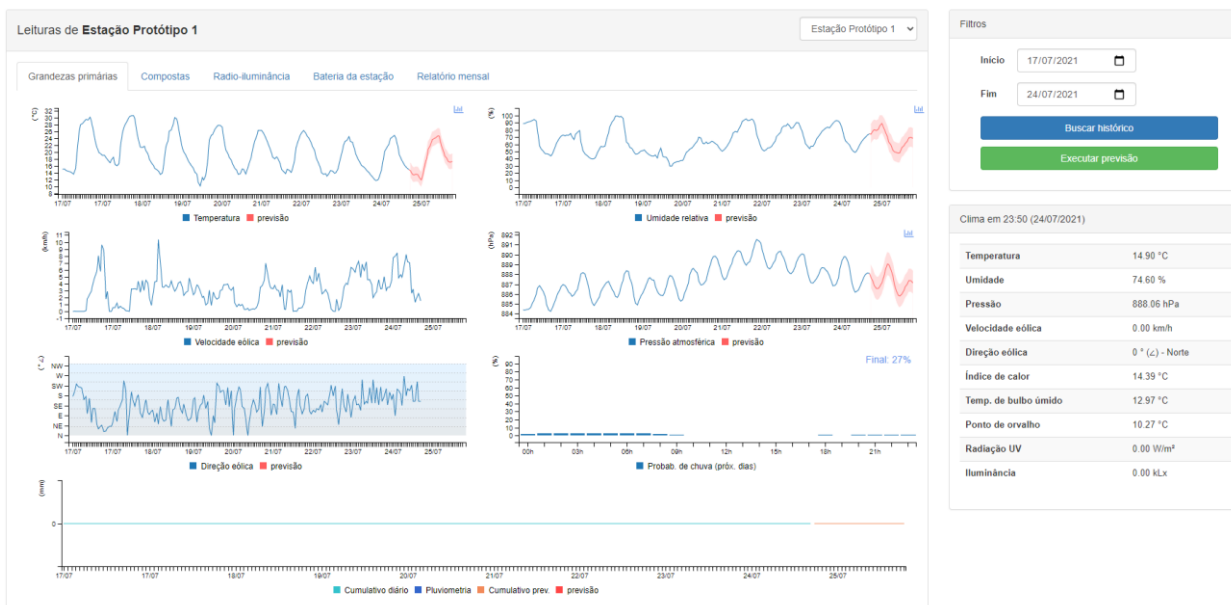


A quantidade de bits faz alusão à arquitetura de CPU do microcontrolador utilizado). Destarte, vide as figuras seguintes com capturas de tela deste ambiente:

**Figura 25** – Página inicial do sistema logo após o login, com o histórico registrado dos últimos dias.



**Figura 26** – Previsões na página inicial.



**Figura 27** - Painel de informações com os dados mais recentes para a janela temporal selecionada em “filtros”. Informações de 24/07/2021 às 23:59.

Clima em 23:50 (24/07/2021)	
Temperatura	14.90 °C
Umidade	74.60 %
Pressão	888.06 hPa
Velocidade eólica	0.00 km/h
Direção eólica	0 ° (∟) - Norte
Índice de calor	14.39 °C
Temp. de bulbo úmido	12.97 °C
Ponto de orvalho	10.27 °C
Radiação UV	0.00 W/m <sup>2</sup>
Iluminância	0.00 kLx

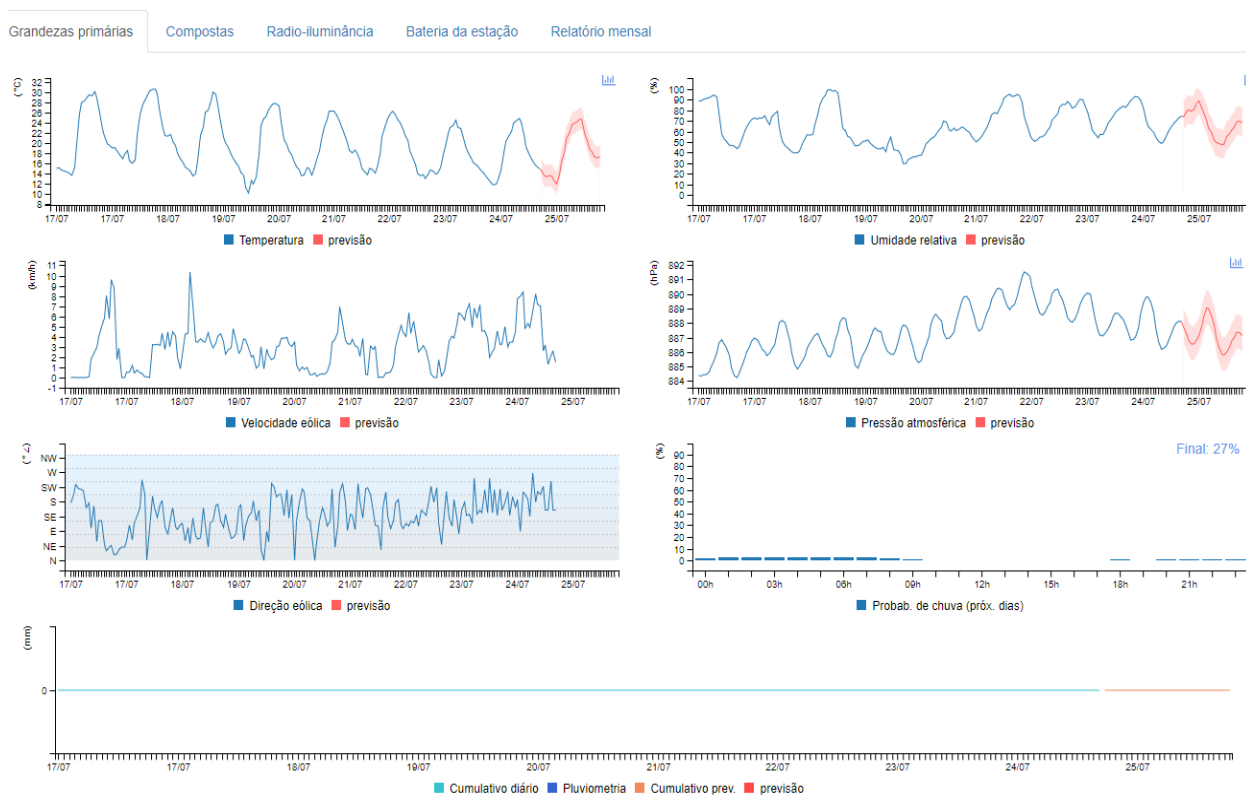
**Fonte:** (Autor, 2021).

A aba de grandezas principais (Figura 28) exhibe dados como temperatura, umidade relativa, velocidade do vento, pressão atmosférica, direção eólica e pluviometria (bem como a probabilidade de chuva, uma vez executadas as previsões). Em suma, exibem dados mensurados por sensores especializados. As compostas (Figura 29) contêm grandezas constituídas por combinações numéricas de outras (como o ponto de orvalho e índice de calor) ou regressões para estimativas, sendo este o caso do índice de evaporação e da temperatura de bulbo úmido. Por fim, radio iluminância (Figura 30) faz referência à irradiância UV e iluminância ambiente; a aba de bateria (Figura 31) fornece as tensões e porcentagens de carregamento da estação; e os relatórios (Figura 32) informam as estatísticas de avaliação dos meteogramas.

Para os gráficos exibidos, tem-se os dados históricos em azul e as previsões em vermelho envoltas por um intervalo de confiança, correspondendo este ao RMSE médio do modelo para esta grandeza. A exceção à regra citada é a probabilidade de chuva, pois todo o gráfico se dá por barras azuis e se trata de uma previsão para as próximas horas. Ademais, é interessante ressaltar as zonas no gráfico de direção eólica, em que cada faixa corresponde a um ponto cardinal/colateral e as linhas variam pelo ângulo a partir do Norte (0° - 360°). Por se tratar de um período de seca, não foram exibidas as barras verticais de pluviometria (que marcariam eventos de chuva e suas previsões contínuas em milimetragem) e a área de seu

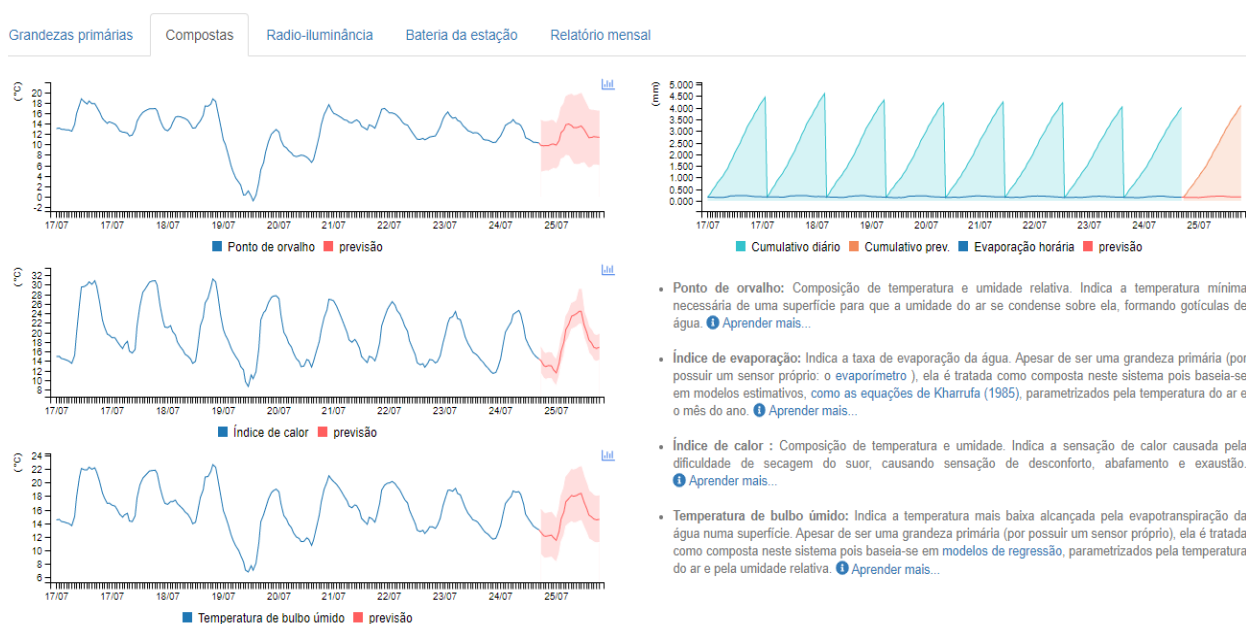
cumulativo, conforme os padrões de meteogramas do INMET.

Figura 28 - Aba de grandezas primárias do sistema web.



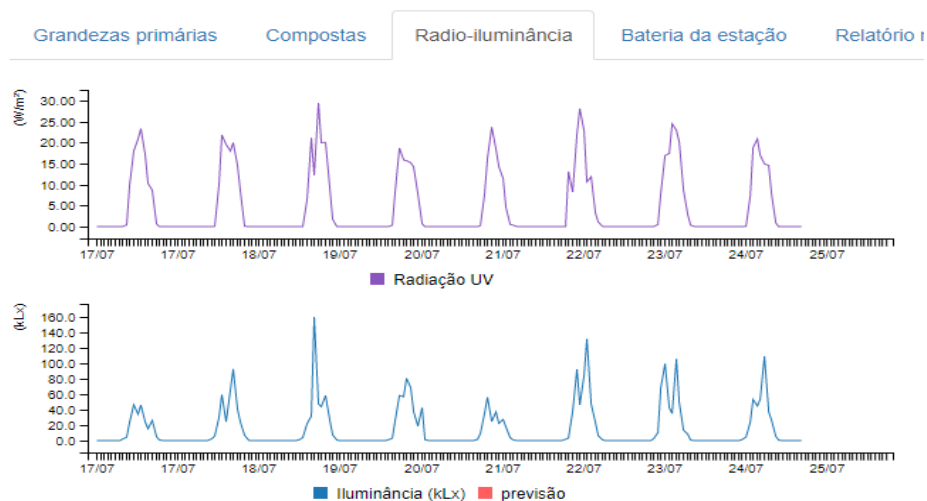
Fonte: (Autor, 2021).

Figura 29 - Aba de grandezas compostas.



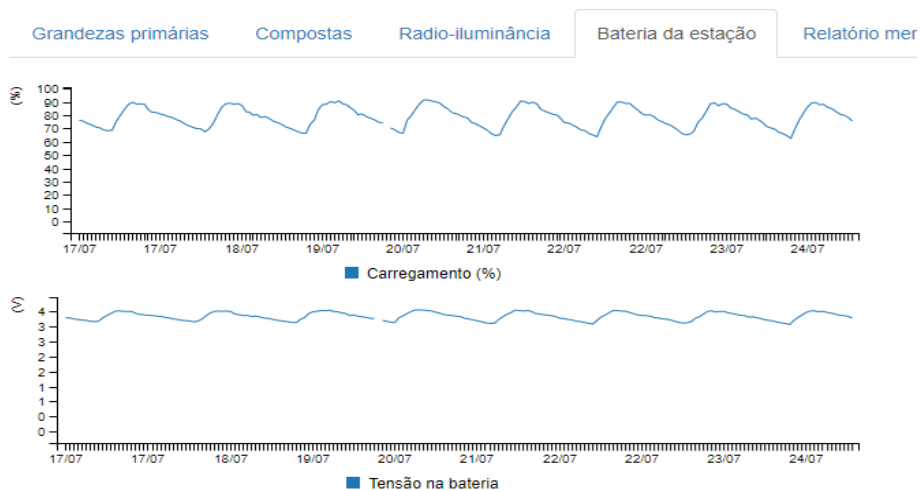
Fonte: (Autor, 2021).

**Figura 30** - Aba de radio-iluminância exibindo a radiação global e a radiação UV.



Fonte: (Autor, 2021).

**Figura 31** - Tensão e porcentagem de carregamento das baterias



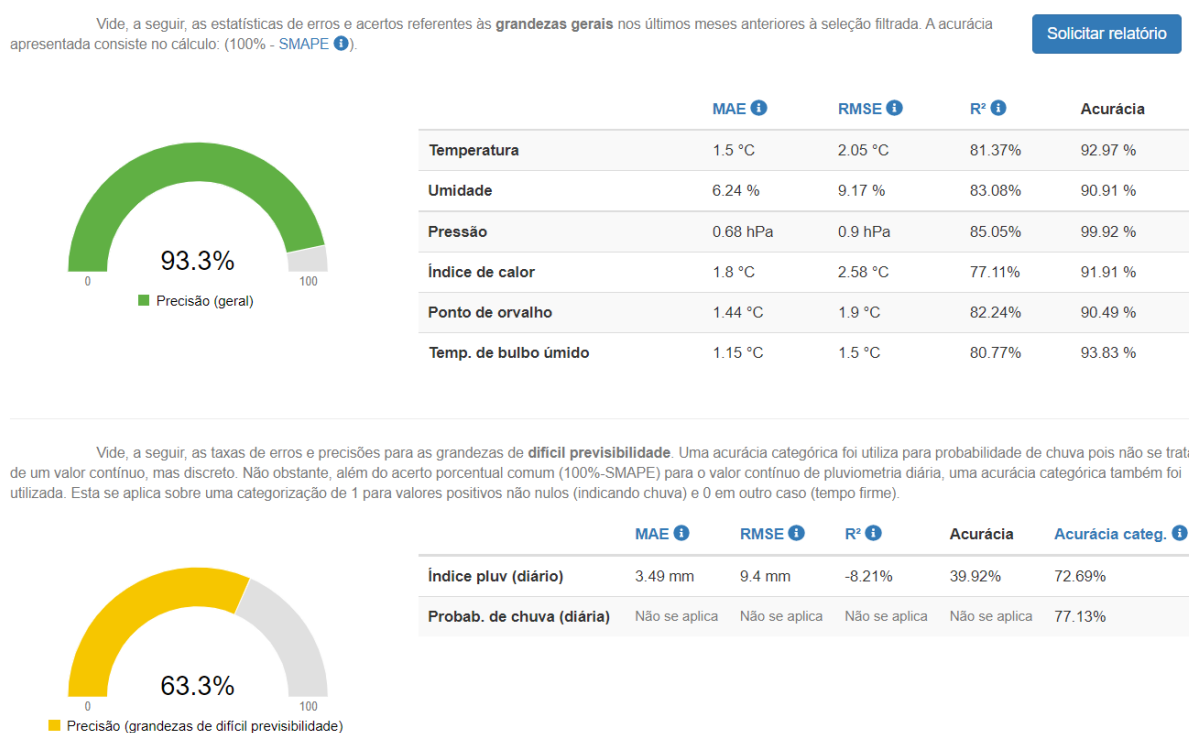
Fonte: (Autor, 2021).

Nota-se, na exibição de “grandezas compostas”, a temperatura de bulbo úmido. Esta não é, por definição, uma composição das grandezas sensorizadas. Em realidade, precisar-se-ia de um termômetro de bulbo úmido para captá-la diretamente, mas inexistente um bom sensor digital desta variável que tenha fácil integração a sistemas embarcados, dificultando sua medição em quase qualquer EMA, sendo esta grandeza uma quase exclusividade de EMC's. Aplicou-se, portanto, uma série de transformações trigonométricas parametrizadas pela temperatura ambiente (bulbo seco) e a umidade relativa para obter a leitura de bulbo úmido com margem de erro ínfima, estando esta modelada pela expressão (6) (STULL, 2021). Já na aba de radio-iluminância, as funções que as parametrizam a radiação UV e a iluminância com

base na tensão de saída de seus sensores estão disponíveis respectivamente pelas expressões (1) e (2).

Por fim, tem-se a aba de relatórios (Figura 32), em que são exibidas as estatísticas de avaliação e performance do modelo. Para tal, foram utilizadas funções como MAE, RMSE,  $R^2$ , uma acurácia percentual, bem como uma categórica para classificação binária entre “chuva” e “não chuva” (intervalos de 24h). Todas estas estatísticas estão corretamente descritas nas equações da expressão (12).

**Figura 32** - A primeira tabela se refere à avaliação do modelo para temperatura, umidade, pressão e seus derivados. A segunda tabela apresenta os mesmos indicadores estatísticos, acrescido de uma acurácia categórica para probabilidade de chuva.



Fonte: (Autor, 2021).

## 4 RESULTADO E DISCUSSÃO

Neste capítulo serão discutidos os resultados técnicos do módulo anterior. Começando por aspectos físicos, o funcionamento eletrônico da estação é consistente e não se observaram travamentos desde a implementação do *Watchdog Timer*.

Já o que se refere à confiança dos dados colhidos, tem-se majoritariamente bons resultados conforme observado na Tabela 5, em que foi obtida uma correlação superior a 90% para todas as quatro grandezas de previsão. As duas variáveis eólicas trabalhadas, no entanto, não obtiveram uma verossimilhança satisfatória com os dados da Estação 001 (o que não quer dizer, obrigatoriamente, que não são confiáveis para o ponto geográfico observado em questão, haja vista diferenças microclimáticas).

Quanto à qualidade das previsões, vide a Tabela 6. e suas estatísticas de avaliação. Nesta, é observada boa performance na maioria dos dados contínuos, mantendo acurácias percentuais acima de 90% e coeficientes de determinação entre 77 e 86%. A única exceção para este foi a análise contínua da pluviometria (cumulação diária), que exibiu  $R^2$  negativo e acurácia contínua de aproximados 40%. No entanto, esta mesma grandeza prevista demonstrou acurácia categórica binária (“chuva” ou “não chuva”, neste caso) de 72%, ligeiramente inferior aos 77% performados pela grandeza associada de “probabilidade de chuva”. A temperatura obteve erro médio absoluto de 1,5 °C, enquanto a umidade e a pressão mantiveram aproximados 6% e 0.68 hPa, respectivamente. Ademais, a média entre as acurácias categóricas e contínuas percentuais foi de 90,91%. De tal forma, desprende-se que a maioria das variáveis demonstram boa precisão e, embora a cumulação milimétrica de pluviometria não esteja tão fiel aos dados reais, esta exhibe boa performance para a definição binária de sua grandeza.

## 5 CONSIDERAÇÕES FINAIS

### 5.1 Reprodutibilidade do Protótipo e Recursos Materiais Necessários

Segue a Tabela 7 com valores aproximados para a construção de um exemplar do protótipo apresentado. Os valores unitários foram mensurados através de sites de vendas tais quais Ali Express, Mercado Livre, dentre comércios locais e diversos outros (taxa de entrega não inclusa). Estes valores não representam o utilizado pelo autor dos recursos universitários, pois diversos destes componentes já eram posse pessoal do aluno durante a concepção prática e teórica do projeto. Outrossim, tais valores são suscetíveis a flutuações para mais ou para menos (conforme seu barateamento/encarecimento no mercado e o cenário econômico vigente). Supondo uma margem de segurança arbitrária de 20% nas variações mercadológicas, tem-se um preço médio entre R\$1000 e R\$1500 para o dado projeto.

**Tabela 7** - Tabela de materiais, unidades e preços estimados.

	Preço UN (R\$)	Unidades	Preço Total (R\$)
DHT22	20,00	1,00	20,00
BMP180 (5 pinos)	10,99	1,00	10,99
ML8511	26,50	1,00	26,50
ESP32	40,00	1,00	40,00
LDR	3,00	1,00	3,00
Fonte (entrada 12, saída 3.3/5)	19,90	1,00	19,90
Placa Solar 9v 3.5w 0.38a Com Saída P4	78,99	4,00	315,96
módulo recarregador 5V-12V a 9V UPS	39,99	1,00	39,99
Bateria Lítio Recarregável 18650 3.7v 2600mAh	20,69	4,00	82,76
Abrigo meteorológico termo higrométrico + anemômetro e biruta	679,90	1,00	679,90
Placa 10x15 Universal Padrão Perfurada Ilhada	16,32	1,00	16,32
Sucata de alumínio, PVC + fios de telefone e rede para reutilização	-	-	-
<b>Total:</b>			<b>1255,32</b>

Fonte: (Autor, 2021).

## 5.2 Conclusões

Por fim, a estação prototipada e o sistema desenvolvidos são capazes de armazenar históricos de diversas análises climatológicas, bem como prever as próximas 24h com qualidade satisfatória, estando no escopo de acerto apresentado pela Tabela 6. O corpo eletrônico, por sua vez, possui implementação física reproduzível em outros ambientes.

Destarte, é possível aplicá-la enquanto *software* acadêmico para universidades, sendo útil para cursos tais quais Agronomia, Geologia, Geografia, Arquitetura e Urbanismo, Ciências Biológicas, dentre diversos outros que lidam com estudos de bioma e clima. A visualização dos aspectos físicos em campo, bem como a utilização de dados digitais em laboratório de informática poderiam compor, por exemplo, uma cadeira de “Meteorologia e Climatologia com Laboratório”, além de auxiliar outras e fornecer dados para pesquisas relacionadas a mudanças climáticas. Tem-se ainda que o protótipo apresentado pode ser largamente aplicado no agronegócio.

## 5.3 Proposta de Trabalhos Futuros

É de interesse do autor desenvolver continuidades deste projeto para proposta de artigos em TCC e possíveis melhorias a nível de mestrado. Nestes contextos, fatores como melhores regressões de correlação geográficas (11) seriam viáveis, haja vista um maior tempo para colher dados de um ciclo anual. Outrossim, melhorias anemométricas seriam possíveis, bem como a implementação de um exemplar deste projeto em campuses universitários do DF, para servir como material de demais pesquisas e apoio para disciplinas que abordem estudos biogeoclimáticos.



## BIBLIOGRAFIA

ABADI, Martín et al. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software Disponível em tensorflow.org.

ALBEROLA, J. *et al.* Ultra Low Power Wireless Weather Station. *In: Sensor Technologies and Applications*. 2007. Valencia, Espanha: IEEE, 2007, p. 469-474.

ALBERTIN, A. L.; ALBERTIN, R. M. *A Internet das Coisas Irá Muito Além das Coisas*. 2017. São Paulo: GV-Executivo, vol. 16, n.2, p.12 – 17.

ANDERSON, G. Brooke; Bell, Michelle L.; Peng, Roger D. (2013). "*Methods to Calculate the Heat Index as an Exposure Metric in Environmental Health Research*". *Environmental Health Perspectives*. 121 (10): 1111-1119. doi:10.1289/ehp.1206273. PMC 3801457. PMID 23934704.

AOSONG ELECTRONICS CO. Digital-output relative humidity & temperature sensor/module DHT22 (DHT22 also named as AM2302). Disponível em <<https://www.sparkfun.com/datasheets/Sensors/Temperature/DHT22.pdf>>. Acessado em: maio 2021.

BOSCH SENSORTEC. Datasheet BMP180 Digital pressure sensor. Disponível em <<https://cdn-shop.adafruit.com/datasheets/BST-BMP180-DS000-09.pdf>>. Acessado em: abril 2019.

BOUKABARA, Sid-Ahmed *et al.* Artificial Intelligence May Be Key to Better Weather Forecasts: Recent advances in machine learning hold great potential for converting a deluge of data into weather forecasts that are fast, accurate, and detailed. EOS, [s. l.], ano 2020, 1 ago. 2019.

CASA DA ROBÓTICA, 2021. Kit Diy Ups Carregador Solar Com Bateria 18650 Saida 9v + Nf. Mercado Livre, 2021. Disponível em < [https://produto.mercadolivre.com.br/MLB-1791083690-kit-diy-ups-carregador-solar-com-bateria-18650-saida-9v-nf-\\_JM?quantity=1](https://produto.mercadolivre.com.br/MLB-1791083690-kit-diy-ups-carregador-solar-com-bateria-18650-saida-9v-nf-_JM?quantity=1)>. Acessado em 12 abr. 2021.

CGEE (Brasília). Sistema de Observação e Detecção dos Impactos das Mudanças Climáticas: Subsídios para Implantação de Sistemas de Observação e Monitoramento dos Impactos das Mudanças Climáticas no Brasil: Produto 2. Relatórios de Projetos, [S. l.], página 15 a 15, nov. 2013. Disponível em < [https://www.cgee.org.br/documents/10195/734063/Produto2\\_Subst%C3%AAdio+Sistema+Observa%C3%A7%C3%A3o+Monitoramento+Impactos+MC\\_9353.pdf/10f21f03-9278-4bb4-8960-962bdec7de7d?version=1.0](https://www.cgee.org.br/documents/10195/734063/Produto2_Subst%C3%AAdio+Sistema+Observa%C3%A7%C3%A3o+Monitoramento+Impactos+MC_9353.pdf/10f21f03-9278-4bb4-8960-962bdec7de7d?version=1.0)>. Acessado em 05 out 2021.

COMPONENTS 101. 2018. BMP180 - Atmospheric Pressure Sensor. Disponível em: < <https://components101.com/sensors/bmp180-atmospheric-pressure-sensor> >. Acessado em 27 mai. 2021.

CONHECENDO O ESP32 – INTRODUÇÃO (1). ELETROGATE. Disponível em: < <https://blog.eletrogate.com/conhecendo-o-esp32-introducao-1/> >. Acessado em 15 mai. 2020.

COSTA, C. L.; OLIVEIRA L.; MOTA, L. M. S. Internet das coisas (IOT): um estudo exploratório em agronegócios. *In: Simpósio da Ciência do Agronegócio (CIENAGRO)*, 6., 2018. Porto Alegre. Anais... Porto Alegre: UFRGS, 2018, p. 184 – 293.

DOZAT, Timony. Incorporating Nesterov momentum into Adam, in Proc. 4th Int. Conf. Learning Representations Workshops. San Juan, Puerto Rico, Maio, 2016.

ESPRESSIF. ESP32 Overview: A feature-rich MCU with integrated Wi-Fi and Bluetooth connectivity for a wide-range of applications. Disponível em <<https://www.espressif.com/en/products/socs/esp32/overview> >. Acessado em 15 mai. 2020.

FAO (ROMA). Food and agriculture organization of the united nations. Crop water requirements. FAO irrigation and drainage paper, roma, ano 1977, n. 24, 1977.

FREITAS, Aline de. A Estação Meteorológica Da Universidade Federal De Uberlândia Como Ferramenta Para O Ensino De Climatologia. Revista de Ensino de Geografia, Uberlândia, v. 3, n. 5, p. 64-75, jul./dez. 2012.

GOOGLE, INC. Google Maps. Disponível em: <https://www.google.com/maps/>. Acesso em: 12 de jul. de 2021.

GOSH, A. et al. Solar Powered Weather Station and Rain Detector. *In: Texas Instruments India Educators' Conference (TIIEC)*. 2013. Bangalore, India: IEEE, 2013, p. 131-134.

GUNDALIA, MANOJ J. et al Int. Journal of Engineering Research and Applications [www.ijera.com](http://www.ijera.com) ISSN: 2248-9622, Vol. 3, Issue 6, nov-dec 2013, pp.64-70.

HARRIS, C.R. *et al.*, 2020. Array programming with NumPy. *Nature*, 585, pp.357–362.

HASAN, Nasimul et al. Automated Weather Event Analysis with Machine Learning. International Conference on Innovations in Science, Engineering and Technology (ICISSET), Dhaka, Bangladesh, 29 out. 2016.

KINGMA, D.P. *et al*: A method for stochastic optimization. In Proceedings of the 3rd International Conference for Learning Representations—ICLR 2015, San Diego, CA, USA, 7–9 Maio de 2015. Disponível em <<https://arxiv.org/abs/1412.6980>>. Acessado jul., 2021.

KOEHRSEN, Will. Random Forest in Python: A Practical End-to-End Machine Learning Example. *In*: KOEHRSEN, Will. Random Forest in Python: A Practical End-to-End Machine Learning Example. [S. l.], 1 dez. 2017. Disponível em: <<https://towardsdatascience.com/random-forest-in-python-24d0893d51c0>>. Acesso em: 16 maio 2020.

KOEHRSEN, Will. Random Forest in Python: A Practical End-to-End Machine Learning Example. *In*: MOREL, Richard. La plaquette contrôleur multifonctions (CTRL MF) version 8,0 et 8,1 versus les «ESP32 DEVKIT V1» 30 broches et 36 broches. [S. l.], 6 dez. 2018. Disponível em: <https://espacerm.com/webgen/tag/electronique/>. Acesso em: 16 maio 2020.

LAPIS SEMICONDUCTOR. ML8511: UV Sensor with Voltage Output. Disponível em <[https://cdn.sparkfun.com/datasheets/Sensors/LightImaging/ML8511\\_3-8-13.pdf](https://cdn.sparkfun.com/datasheets/Sensors/LightImaging/ML8511_3-8-13.pdf)>. Acessado em: março 2020.

LAZZARI, Francini Meneghini *et al*. Revolução Verde: Impactos Sobre os Conhecimentos Tradicionais. *In*: Congresso Internacional de Direito e Contemporaneidade, 4., 2017.- Santa Maria. Anais... Santa Maria: Ed. UFSM, 2017. p.2

LUIZ, Walter et al. Intercomparação de pluviômetros de balança por meio de um sistema de verificação em laboratório. SEPEI, Santa Catarina, ano 2013.

MOREIRA, R. J. Críticas Ambientistas à Revolução Verde. 2000. Estudos Sociedade e Agricultura, Rio de Janeiro, n.15, p.39-52, out. 2000.

MORENO ORDONEZ, EDWARD D.; GIACOMINI PENTEADO, C; CÉSAR RODRIGUES DA SILVA, ALEXANDRE. Microcontroladores e FPGAs: Aplicações em Automação. São Paulo: Novatec Editora Ltda, 2006.

PEDREGOSA, Fabian *et al.* Machine Learning in Python, JMLR 12, pp. 2825-2830, 2011.

PEREIRA, A.R.; ANGELOCCI, L.R.; SENTELHAS, P.C. Agrometeorologia: fundamentos e aplicações práticas. Porto Alegre: Guaíba Agropecuária, 2002, p.478

R. L. SNYDER, *et al.* A Guide to Automated Weather Station Networks in North America. In: G. STANHILL. Advances in Bioclimatology\_4. Berlim: Springer-Verlag, 1996

SALMAN, Man Gali *et al.* Weather Forecasting using Deep Learning Techniques. International Conference on Advanced Computer Science and Information Systems ICACSIS, Depok, Indonésia, ano 2015, 10 oct. 2015.

SCHWAB, K. A Quarta Revolução Industrial. São Paulo: Edipro, 2016.

SENSIRION, THE SENSOR COMPANY. Datasheet SHT1x (SHT10, SHT11, SHT15) Humidity and Temperature Sensor, 2008. Disponível em <[https://www.sparkfun.com/datasheets/Sensors/SHT1x\\_datasheet.pdf](https://www.sparkfun.com/datasheets/Sensors/SHT1x_datasheet.pdf)>. Acessado em: março 2020.

SÔNEGO, A. A.; MARCELINO, R; GRUBER, V. A Internet das Coisas aplicada ao conceito de eficiência energética: uma análise quantitativo-qualitativa do estado da arte da literatura. AtoZ: Novas Práticas em Informação e Conhecimento, Santa Catarina, v.5 n. 2, p. 80 – 90. 2016.

SOUZA, David José de; LAVINIA, Nicolás C. Conectando o PIC 16F877A: Recursos Avançados, 4ª Ed., São Paulo: Érica, 2007.

STULL, 2011. Wet-bulb temperature from relative humidity and air temperature. J. Appl. Meteorol. Climatol., 50 (2011), pp. 2267-2269

SUNDMAEKER, H. *et al.* Internet of Food and Farm 2020. Digital and Virtual Worlds, n. January, p. 129–152, 2016.

VARSAMOPOULOS, Savvas & Bertels, Koen & Almudever, Carmen. Designing neural network based decoders for surface codes. 2018. Disponível em <[https://www.researchgate.net/publication/329362532\\_Designing\\_neural\\_network\\_based\\_decoders\\_for\\_surface\\_codes](https://www.researchgate.net/publication/329362532_Designing_neural_network_based_decoders_for_surface_codes)>. Acessado em jul. 2021.

ZHAO, Rui et al. Deep Learning and Its Applications to Machine Health Monitoring: A Survey. 2016. Disponível em <[https://www.researchgate.net/publication/311839720\\_Deep\\_Learning\\_and\\_Its\\_Applications\\_to\\_Machine\\_Health\\_Monitoring\\_A\\_Survey](https://www.researchgate.net/publication/311839720_Deep_Learning_and_Its_Applications_to_Machine_Health_Monitoring_A_Survey)>. Acessado em jul. 2021.

