



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**  
**PROGRAMA DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**LEVI MAIA ALVES**

**DESENVOLVIMENTO E IMPLANTAÇÃO DE UM PROTÓTIPO DE UMA  
PLATAFORMA IoT PARA MONITORAMENTO DE UMA CENTRAL DE GERAÇÃO  
FOTOVOLTAICA**

**FORTALEZA**

**2022**

LEVI MAIA ALVES

DESENVOLVIMENTO E IMPLANTAÇÃO DE UM PROTÓTIPO DE UMA  
PLATAFORMA IoT PARA MONITORAMENTO DE UMA CENTRAL DE GERAÇÃO  
FOTOVOLTAICA

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia Elétrica do  
Centro de Tecnologia da Universidade Federal  
do Ceará, como requisito parcial à obtenção do  
grau de bacharel em Engenharia Elétrica. Área  
de Concentração: Energias Renováveis

Orientador: Prof. Dr. Paulo Cesar Marques de  
Carvalho

Coorientadora: Dr<sup>a</sup> Ivonne Montero Dupont

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- A48d Alves, Levi Maia.  
Desenvolvimento e implantação de um protótipo de uma plataforma IoT para monitoramento de uma central de geração fotovoltaica / Levi Maia Alves. – 2022.  
81 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Elétrica, Fortaleza, 2022.  
Orientação: Prof. Dr. Paulo Cesar Marques de Carvalho.  
Coorientação: Profa. Dra. Ivonne Montero Dupont.
1. Energia Solar FV. 2. Telemetria. 3. Previsão de Corrente Elétrica. 4. LSTM. I. Título.
- CDD 621.3
-

LEVI MAIA ALVES

DESENVOLVIMENTO E IMPLANTAÇÃO DE UM PROTÓTIPO DE UMA  
PLATAFORMA IoT PARA MONITORAMENTO DE UMA CENTRAL DE GERAÇÃO  
FOTOVOLTAICA

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia Elétrica do  
Centro de Tecnologia da Universidade Federal  
do Ceará, como requisito parcial à obtenção do  
grau de bacharel em Engenharia Elétrica. Área  
de Concentração: Energias Renováveis

Aprovada em: 17/06/2022.

BANCA EXAMINADORA

---

Prof. Dr. Paulo Cesar Marques de Carvalho (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Raimundo Furtado Sampaio  
Universidade Federal do Ceará (UFC)

---

Msc. Leonarda Feitosa Cajuaz Castro  
Universidade Federal do Ceará (UFC)

Aos meus pais, Leonel Maia e Silva Neto e  
Liergina Pedrosa Alves e Silva

**AGRADECIMENTOS**

Principalmente a minha família no qual sou muito agradecido e privilegiado, que me possibilitou concluir o curso sem fazer-me preocupar com outras questões além da minha própria educação.

A Empresa Sunne Energias Renováveis e seus colaboradores que por meio de pessoas, possibilitou junto ao Banco do Nordeste o financiamento para a elaboração do projeto.

Ao Prof. Dr. Paulo Cesar Marques de Carvalho, pela excelente orientação.

Aos professores participantes da banca examinadora Raimundo Furtado Sampaio e Leonarda Feitosa Cajuaz Castro pelo tempo, pelas valiosas colaborações e sugestões.

Aos professores que me ajudaram e mesmo em momentos difíceis me deram valiosas lições.

As amigas construídas que através de risadas e brincadeiras durante o curso possibilitaram atravessar esse caminho que por vezes parecia ser tortuoso e duradouro.

A todos que fizeram parte desses cinco, quase seis anos de curso e que com qualquer ação animadora ou motivadora me deram mais força para concluí-lo.

“O que pensas de ti próprio é muito mais importante do que o que os outros pensam de ti.”  
(Sêneca, 50 D.C).

## RESUMO

A maioria dos modelos de previsão de geração de energia para centrais fotovoltaicas (FVs) são construídos incluindo apenas as variáveis de temperatura ambiente e radiação. Porém, há fatores climáticos que influenciam também na produção de eletricidade, como umidade ambiente e velocidade do vento. Devido ao aumento do uso de dispositivos de internet das coisas (IoT), o monitoramento remoto de variáveis em tempo real remotamente, também denominado telemetria, torna-se cada vez mais importante para as análises de produção de usinas FVs. Estimar a quantidade de energia gerada é de extrema importância para qualidade da energia inserida na rede elétrica. O objetivo deste trabalho é apresentar o desenvolvimento e implantação de um Protótipo de uma Plataforma IoT para Monitoramento de uma Central de Geração Fotovoltaica que fora iniciado em meados de 2019, a começar da concepção da ideia até a obtenção dos dados até a aplicação de redes neurais LSTM (Memoria de Curto e Longo Prazo) que prevê os dados de corrente elétrica. Os dados foram coletados a partir de uma estação meteorológica instalada ao lado dos painéis FVs, as variáveis analisadas são: temperatura dos painéis, temperatura ambiente, umidade, velocidade do vento e irradiância incidente sobre o módulo. Esses dados são cadastrados na rede neural para o processamento dos dados de corrente elétrica. Os resultados evidenciaram o passo a passo do projeto e apresentou bons valores de estimação para o curto número de dados possuídos, dispondo de um erro menor que 0.77A em 75% dos dados analisados, além de coeficiente de correlação com os dados do inversor de 0.947 que nos permitiu concluir que há viabilidade técnica para utilização de algoritmos de aprendizado de máquina para prever dados de corrente elétrica em uma usina FV através de dados climatológicos.

**Palavras-chave:** Energia Solar FV; Telemetria; Previsão de Corrente Elétrica; LSTM



## RÉSUMÉ

La plupart des modèles de prévision de la production d'énergie pour les centrales photovoltaïques (PV) sont construits en incluant uniquement les variables de température et de rayonnement ambiants. Cependant, certains facteurs climatiques influencent également la production d'électricité, comme l'humidité ambiante et la vitesse du vent. En raison de l'utilisation accrue des dispositifs de l'internet des objets (IoT), la surveillance à distance des variables en temps réel, également appelée télémétrie, devient de plus en plus importante pour les analyses de production des centrales photovoltaïques. L'estimation de la quantité d'énergie produite est de la plus haute importance pour la qualité de l'énergie insérée dans le réseau électrique. L'objectif de ce travail est de présenter le développement et la mise en œuvre d'un prototype d'une plateforme IoT pour la surveillance d'une centrale photovoltaïque qui avait été lancée à la mi-2019, en partant de la conception de l'idée à l'obtention des données jusqu'à l'application de réseaux neuronaux LSTM (Short and Long Term Memory) qui prédit les données de courant électrique. Les données ont été collectées à partir d'une station météorologique installée à côté des panneaux photovoltaïques. Les variables analysées sont : la température du panneau, la température ambiante, l'humidité, la vitesse du vent et l'irradiation incidente sur le module. Ces données sont enregistrées dans le réseau neuronal pour le traitement des données de courant électrique. Les résultats ont montré la progression du projet et ont présenté de bonnes valeurs d'estimation pour le petit nombre de données possédées, avec une erreur inférieure à 0,77A dans 75% des données analysées, en plus d'un coefficient de corrélation avec les données de l'onduleur de 0,947, ce qui nous a permis de conclure qu'il y a une faisabilité technique pour l'utilisation d'algorithmes d'apprentissage automatique pour prédire les données de courant électrique dans une installation PV à travers des données climatologiques.

**Mots clés:** Énergie Solaire Photovoltaïque; Télémétrie; Prévision du Courant électrique; LSTM

## LISTA DE FIGURAS

Figura 1	– Matriz Elétrica Nacional.....	15
Figura 2	– Ranking municipal de Potência Instalada.....	16
Figura 3	– Aplicação da Internet das Coisas na pesquisa .....	16
Figura 4	– Evolução da Fonte Solar FV no Brasil nos últimos 10 anos.....	21
Figura 5	– Curva IxV pela influência da irradiância.....	24
Figura 6	– Curva IxV pela influência da temperatura.....	25
Figura 7	– Variação da potência de saída sob temperatura constante e aumento controlado na umidade relativa do ar.....	26
Figura 8	– Boxplot e suas medidas estatísticas.....	29
Figura 9	– Estrutura analítica da Pesquisa.....	30
Figura 10	– Banco de dados do Firebase .....	32
Figura 11	– Monitoramento ao vivo da plataforma ThingSpeak.....	33
Figura 12	– Levantamento dos materiais.....	34
Figura 13	– Visão do Esquemático do projeto da pesquisa.....	35
Figura 14	– Visão das trilhas da placa.....	36
Figura 15	– Componentes utilizados para a execução do Projeto da pesquisa no Altium..	36
Figura 16	– Placa de Circuito Impresso.....	37
Figura 17	– Funcionamento elétrico do Anemômetro.....	39
Figura 18	– Lista Encadeada Circular.....	75
Figura 19	– Aplicação ThingSpeak.....	41
Figura 20	– Ilustração do banco de dados.....	41
Figura 21	– Ilustração com o comando de alteração remota.....	42
Figura 22	– Desenho da instalação do sistema.....	43
Figura 23	– Dimensões da planta FV.....	43

Figura 24	– Levantamento de Materiais.....	44
Figura 25	– Local de fixação do sensor de corrente.....	75
Figura 26	– Ponto de conexão Wi-Fi.....	76
Figura 27	– Ponto de Conexão 220V.....	76
Figura 28	– Local de Fixação da instalação.....	77
Figura 29	– Caixa hermética dos sensores de corrente.....	45
Figura 30	– Fixação da estação meteorológica em campo.....	46
Figura 31	– Estação Meteorológica.....	47
Figura 32	– Maneira de fixação Sensor de Temperatura.....	48
Figura 33	– Abertura do Circuito das Strings.....	49
Figura 34	– Sensores plug and play de Corrente instalados .....	49
Figura 35	– Soldagem do Sensor de temperatura e cabo manga 3 vias.....	50
Figura 36	– Módulo Sonoff.....	51
Figura 37	– Dados enviados sensor de temperatura 03.....	51
Figura 38	– Filtro Passa-Baixa.....	52
Figura 39	– Reed Switch do anemômetro que precisou ser trocado.....	53
Figura 40	– ThingSpeak com as variáveis Temperatura e Corrente.....	54
Figura 41	– ThingSpeak com as variáveis ambiente.....	54
Figura 42	– Estação em funcionamento executando testes locais.....	55
Figura 43	– Monitoramento local das variáveis.....	56
Figura 44	– Posição final do sensor de irradiância.....	77
Figura 45	– Análise de correlação das variáveis coletadas.....	59
Figura 46	– Análise de correlação das variáveis principais.....	61
Figura 47	– Arquitetura da rede neural desenvolvida para o modelo em questão.....	62

Figura 48	– Resultado final do treinamento analisando a perda nos dados de treino e teste.....	63
Figura 49	– Dispersão de dados entre os valores de corrente do sensor WCS1800 e do Inversor.....	63
Figura 50	– Dispersão dos dados de diferença entre os valores de corrente coletados.....	64
Figura 51	– Comparação do modelo em todo o período de teste.....	65
Figura 52	– Representação do modelo nos últimos 5 dias de teste.....	66
Figura 53	– Análise de dispersão dos dados preditos e medidos pelo WCS1800.....	67
Figura 54	- Boxplot da diferença entre os valores de corrente coletados pelo sensor.....	68
Figura 55	– Boxplot da diferença entre os valores de corrente medidos pelo inversor e preditos.....	68
Figura 56	– Análise do modelo sem a velocidade do vento em todo o período de teste.....	69

## LISTA DE TABELAS

Tabela 1 – Análise de diferentes redes neurais para distintas estações do ano.....	23
Tabela 2 – Definição de sensores iniciais.....	31
Tabela 3 – Valores máximo e mínimo de todas.....	60
Tabela 4 – Comparação de erros entre os modelos com e sem velocidade do vento.....	70

## **LISTA DE ABREVIATURAS E SIGLAS**

FV	Fotovoltaico
IoT	Internet Das Coisas
GDFV	Geração Distribuída Fotovoltaica
TCC	Trabalho de Conclusão de Curso
QEE	Qualidade de Energia Elétrica
RNN	Redes Neurais Recorrentes

## LISTA DE SÍMBOLOS

% Porcentagem

**R\$** Real

**s** Segundos

**M** Mega

**G** Giga

## SUMÁRIO

1	<b><u>INTRODUÇÃO</u></b> .....	14
1.1	Objetivos Gerais.....	18
1.2	Objetivos Específicos.....	18
1.3	Estrutura do Trabalho.....	19
2	<b><u>REVISÃO BIBLIOGRÁFICA</u></b> .....	20
2.1	Estado da arte.....	20
2.2	Referencial Teórico.....	23
2.2.1	Influência das variáveis na geração FV.....	23
2.2.1.1	Influência da Radiação Solar.....	23
2.2.1.2	Influência da temperatura ambiente.....	24
2.2.1.3	Influência da umidade.....	25
2.2.1.4	Influência da velocidade do vento.....	26
2.2.2	Redes Neurais Recorrentes.....	27
2.2.2.1	LSTM (Long Short Term Memory).....	27
2.2.3	Análises Gráficas do Erro.....	29
3	<b><u>MATERIAIS E MÉTODOS</u></b> .....	30
3.1	Desenvolvimento do sistema de Aquisição e Programação no IDE Arduino	30
3.2	Montagem da Placa de Circuito Impresso.....	34
3.3	Utilização dos sensores para teste e conexão ao banco de dados.....	37
3.4	Instalação do sistema no local.....	42
4	<b><u>RESULTADOS E DISCUSSÕES</u></b> .....	58
4.1	Desenvolvimento do algoritmo;;;.....	58
4.2	Análise dos resultados.....	62
4.3	Análise do resultado excluindo velocidade do vento.....	69
5	<b><u>CONCLUSÃO</u></b> .....	70
	<b>PROJETOS FUTUROS</b> .....	74
	<b>REFERÊNCIAS</b> .....	75
	<b>Anexos</b> .....	76



## 1 INTRODUÇÃO

O aumento da população mundial provoca um aumento da demanda de energia elétrica utilizada, que hoje, são em maior parte produzidas pelas fontes de energias convencionais, que, além de poluírem, impactam diretamente na economia por apresentar um custo mais alto do que a utilização de energias alternativas. Por isso, está sendo feito um esforço mundial por parte dos governos para investir na produção das “energias limpas” visando reduzir os efeitos causados pela produção e utilização dos combustíveis fósseis como o impacto no efeito estufa. Diante disso, as energias renováveis, principalmente a eólica e solar apresentam-se, hoje como soluções sustentáveis e duradouras para substituir essas fontes poluentes.

A geração fotovoltaica (FV), tem como o sol a sua principal fonte. Essa energia solar é responsável pelo crescimento da vegetação, pela origem dos ventos, pelo ciclo da água, e é também a razão pela qual temos diferentes climas no planeta Terra. A energia solar é recebida pelas plantas, e, por meio do processo de fotossíntese, é transformada em alimento (VILLALVA, 2012). A energia do Sol também é responsável pela geração dos ventos e dos diferentes climas na Terra. O Sol aquece de forma diferente a superfície da Terra segundo a localização no globo terrestre. Os ventos se formam pela diferença de pressão e temperatura entre as camadas de ar da atmosfera (VILLALVA, 2012).

A geração FV se origina através da transformação da radiação solar em energia elétrica através do efeito FV. Para isso, são utilizados materiais que são capazes de produzir esse efeito, os semicondutores. Esse processo de transformação de radiação em energia elétrica é executado pelas células FV,

De acordo com a Empresa de Pesquisas Energéticas (EPE, 2016) estudos apontam algumas soluções para lidar com a variabilidade das fontes renováveis não despacháveis e, assegurar a estabilidade do sistema garantindo assim, a segurança de suprimento energético. Cabe salientar que entre as principais soluções, destacam-se a previsão da geração de energia elétrica de um sistema FV / eólico.

A matriz elétrica brasileira (Figura 1) é composta em sua maior parte de energias renováveis, com participação maior da energia hidráulica e eólica, porém o crescimento da energia solar, principalmente em residências e pequenos estabelecimentos é de suma importância para o entendimento de qualidade da rede elétrica por tornar a rede mais complexa, com mais atuadores injetando e consumindo energia elétrica afetando toda a cadeia. No Brasil, a maior motivação para o incentivo de novas fontes é a redução da dependência das hidrelétricas que estão sujeitas a períodos de seca (CASTRO, 2018).

Segundo Reinaldo (2020), devido à natureza estocástica da radiação solar, que varia conforme as horas do dia e os efeitos climáticos, a geração distribuída FV (GDFV) apresenta um comportamento de fonte não-despachável. Essa característica pode afetar negativamente os parâmetros de QEE e causar problemas para a rede elétrica.

Com a evolução desses sistemas, é importante que se faça o controle e o monitoramento dos dados de geração e de clima dessas plantas FV, e uma solução para isso são os sistemas de aquisição de dados que se apresentam como uma importante solução para indicar falhas em plantas FV, otimização da eficiência de conversão, bem como estimativa do potencial solar de uma determinada região. (PEREIRA, 2018).


Figura 1 – Matriz Elétrica Nacional. (ABSOLAR 2022)



Fonte: ABSOLAR (2022)

As grandes cidades hoje são as que possuem mais complexidade em suas redes devido ao alto número de consumidores e geradores de energia. Por exemplo, o estado do Ceará junto com sua capital Fortaleza, corresponde a 5º maior capital em relação a potência instalada em geração distribuída fotovoltaica (GDFV) do Brasil (Figura 2). Uma maneira de diminuir a complexidade da rede e torna-la mais previsível é através do monitoramento dos dados e previsão de geração, o que permitirá o melhor controle sobre todas as demais fontes de energias despacháveis.

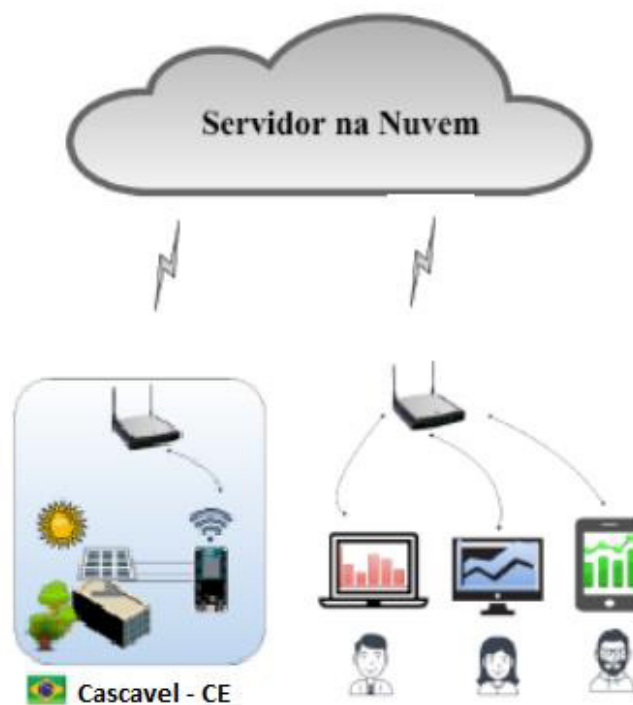
Figura 2- Ranking municipal de Potência Instalada em Geração Distribuída



Fonte: ABSOLAR (2022)

A Internet das Coisas proporciona controlar e medir as grandezas remotamente dispositivos através de uma rede de base, criando uma chance para mais consolidação direta do mundo físico em programas e conseqüente no aumento da eficiência e precisão da previsão e rapidez nas comunicações entre diferentes partes do processo. A utilização do conceito da IoT na pesquisa é coletar os dados no local da usina, enviar para um servidor na nuvem que permite a conexão através de diferentes aplicações para visualizar os dados (Figura 3).

Figura 3 – Aplicação da Internet das Coisas na pesquisa



Fonte: Próprio Autor

Os dados coletados envolvem não apenas os dados de geração de energia, mas também de informações meteorológicas em tempo real que ajuda a compreender a relação com a energia elétrica produzida e a partir disso, reconhecer quando houver painéis defeituosos sendo estes por conectividade, poeira ou simplesmente por queda de eficiência e outros assuntos que podem afetar o desempenho de uma planta solar.

A utilização dos conceitos de IoT possibilita melhorias que diminuem custos. Ao poder monitorar remotamente uma usina para avaliar sua operação, torna-se possível uma percepção de quando será necessária uma manutenção preventiva, identificação de falhas e análise dos dados históricos em relação aos dados atuais para avaliar seu desempenho.

Um estudo realizado por (Yagli, Yang e Dipti, 2019) analisou 5 zonas climáticas diferentes nos Estados Unidos concluiu que 25% na melhoria da previsão da radiação solar pode economizar 1,56% (US\$ 46,5 milhões) nos custos de geração de energia.

Com o advento das microrredes torna-se cada vez mais importante o gerenciamento e previsão desses dados de geração. Portanto a tecnologia para automação e inteligência de monitoramento de plantas FV é responsável pelo crescimento mais sustentável dessa fonte, devido a geração de energia em pequena escala é em sua maior parte proveniente da fonte solar na qual depende de fatores externos não controláveis.

Dentre os fatores externos não controláveis pode-se citar a radiação, temperatura ambiente, velocidade do vento e umidade que são alvos de diferentes pesquisas que visam identificar os efeitos desses fatores no desempenho elétrico dos módulos FV. Além disso, são escassas as pesquisas referentes a projetos de telemetria que visa avaliar a influência das variáveis na produção de energia e prever geração de energia no Nordeste do Brasil. Dito isso, o presente TCC visa conceber a ideia, montar e validar a viabilidade técnica de um projeto de telemetria que possibilite a previsão de valores de corrente gerados em uma usina FV em Cascavel – Ceará. Assim como, analisar os impactos das variáveis externas na produção de energia num clima tropical de acordo com o desempenho dos módulos FV e dos sensores instalados em campo. Esta análise possibilitará antecipar os valores de geração de potência a ser extraído de sistemas FV nos arredores dessa região.

Para isso, nessa pesquisa utilizou-se de módulos FV, sensores, atuadores, dispositivos elétricos e dispositivos eletrônicos conforme serão apresentados posteriormente no Capítulo 2 deste trabalho. Serão explicadas todas as motivações de escolhas de sensores até a exploração minuciosa da instalação em campo de toda a pesquisa que se iniciou em meados de 2019. Os métodos de previsão baseados em séries temporais precisam de dados de medições históricas

de geração de energia, para que a partir destes dados sejam capazes de prever dados futuros. Contudo, o desempenho de um sistema FV conectado à rede depende fortemente das condições climáticas do local de instalação do sistema (Cantor, 2017). Portanto, para uma previsão realista dos dados de geração futura de um sistema FV é preciso considerar os dados climáticos.

É utilizado o conceito de redes neurais artificiais (RNA) para a previsão de corrente produzida por painéis FV. Através de pesquisas relacionadas ao tema, a rede neural recorrente com melhor desempenho foi a LSTM que será aplicada no modelo a partir de dados reais coletados em campo. Neste sentido, o objetivo desse trabalho reside em analisar uma solução viável de um projeto para promover e quantificar a mudança de desempenho da produção da usina FV a partir da telemetria.

É nesse contexto que o presente TCC visa apresentar sua contribuição, analisa-se todos os estudos prévios sobre o assunto, possibilitar a criação de um projeto de telemetria, colocando-o em campo e aplicando análises de dados coletados para prever os dados futuros de geração da usina FV e assim abrindo espaço para discussão de melhoria de performance e facilitar a visualização para realizar uma tomada de ação rápida.

### 1.1 Objetivo Geral

O objetivo principal deste trabalho é apresentar o desenvolvimento e implantação de um Protótipo de uma Plataforma IoT para Monitoramento de uma Central de Geração Fotovoltaica que possibilite a criação de um modelo de previsão de geração que será utilizado visando avaliar o uso de plataformas de visualização para uma melhoria de performance.

### 1.2 Objetivos Específicos

- Analisar a viabilidade de um projeto de telemetria para utilizar em uma planta FV.
- Realizar a análise dos dados coletados pelos sensores e permitir uma fácil visualização.
- Desenvolver um modelo de previsão através da linguagem *Python* com os dados coletados e analisar sua performance em relação aos dados do inversor.
- Avaliar os resultados obtidos.

### 1.3 Estrutura do Trabalho

A estrutura do trabalho divide-se primordialmente em quatro capítulos: No capítulo 1 é feito um estudo a partir de pesquisas preliminares que aborde os temas de impacto de variáveis na geração de energia, também é executado um estudo sobre as redes neurais mais utilizadas nesse tema e principalmente estudos sobre previsão de geração de energia elétrica. No capítulo 2 é abordada toda a parte teórica da concepção até a montagem in loco da aplicação do projeto, abordando também conceitos teóricos de redes neurais e de geração FV. No capítulo 3 é discutida a aplicação e explicação do modelo de rede neural utilizado e também é feita a análise de resultados. Por fim, no capítulo 4 é apresentada uma conclusão e impactos do presente TCC assim como a proposição para trabalhos futuros acerca do tema.

## **2 REVISÃO BIBLIOGRÁFICA**

A revisão da literatura, conforme mostrado na sequência, determina o estado da arte em estudos que analisam a importância da previsão da geração FV. Para entender como esses fatores afetam o comportamento das células FV, é necessário primeiro entender os impactos da radiação solar, temperatura ambiente e outras variáveis. As mudanças climáticas podem afetar os valores de radiação solar, bem como a temperatura ambiente. Além disso, a velocidade do vento e a umidade relativa do ar podem ter impacto direto na temperatura interna da célula, influenciando no seu desempenho. Para prever a geração de energia elétrica através dos efeitos climáticos uma das opções dar-se pela utilização de redes neurais.

### **2.1 Estado da Arte**

De acordo com a IEA (Agência Internacional de Energia), as energias renováveis serão responsáveis por quase 95 % do aumento da capacidade global de energia até 2026, com a energia solar representando mais da metade do aumento. Esse crescimento também está sendo seguido pelo Brasil que no intervalo de 5 anos entre 2017 e 2022 cresceu sua potência instalada FV de 1158 MW para 15001 MW, um aumento de quase 1200% em 5 anos puxado principalmente pelo aumento da Geração Distribuída conforme mostra a Figura 4 da ABSOLAR.

Figura 4 – Evolução da Fonte Solar FV no Brasil nos últimos 10 anos



Fonte: ABSOLAR (2022)

Segundo o Global Future Report 2013 REN21, a capacidade FV pode atingir 8000 GW até 2050. Entretanto, a volatilidade e a intermitência natural da geração FV representam um enorme desafio para solucionar nos sistemas de energia existentes.

Com o crescente aumento de unidades descentralizadas de geração de energia, o constante monitoramento e avaliação tornam-se necessários. De acordo com (WOYTE et al., 2013), um sistema de monitoramento adequado é capaz de detectar problemas operacionais e assim garantir um maior rendimento energético (PEREIRA, 2018).

Uma boa maneira de resolver estes problemas é a previsão de energia gerada. Os métodos de previsão de geração de energia FV estão divididos principalmente em três categorias: modelos físicos, modelos estatísticos, e modelos de aprendizado de máquina.

Nesse trabalho é abordado um modelo de aprendizagem de máquina que é executado através de dados climáticos como velocidade do vento, umidade, temperatura ambiente e das temperaturas dos módulos, irradiância e correntes coletadas em campo. Segundo Andrés (2017, p. 77), “A maioria dos autores enfocam os trabalhos de pesquisa nos dois fatores climáticos que mais afetam o desempenho dos sistemas FV, os quais são temperatura ambiente e radiação. Porém, existem outros fatores climáticos importantes que podem influenciar na produção de



energia elétrica gerada. É assim como nesse trabalho se analisaram os estudos realizados por outros autores respeito de vários fatores climáticos tanto da temperatura ambiente e da radiação, assim como da velocidade do vento, da umidade, e até do albedo”.

Dentre os fatores ambientais que influenciam na potência de saída de uma central FV, as principais variáveis que influenciam a potência são a irradiância no plano do coletor e a temperatura das costas do painel (Pelland et al., 2013). No que se diz a respeito do melhor desempenho do sistema, em (Silva et al, 2018) seria potencialmente atingido sob condições de maior irradiância solar, menor precipitação pluviométrica, menor temperatura, maior velocidade do vento e menor umidade relativa do ar.

Para treinar os modelos de aprendizagem de máquina é necessário escolher a melhor rede neural para entender essa situação de séries temporais de geração FV. Em (QING,2018) resultados experimentais sobre os problemas de previsão mostram que a proposta de aprendizagem, levando em conta as dependências entre horas diferentes de um mesmo dia é muito mais preciso do que alguns outros algoritmos competitivos que preveem apenas uma única saída. Para o conjunto de dados de Cabo Verde com cerca de dois anos de dados de treinamento, o algoritmo de aprendizado Memória de Longo Prazo de Curto Prazo (LSTM) proposto é 18,34% mais preciso do que outro algoritmo de aprendizagem na métrica do RMSE.

As redes LSTM são baseadas em Redes Neurais Recorrentes (RNN). Ao contrário do MLP "normal", O RNN utiliza as informações temporais dos dados de entrada. Um RNN percebe esta capacidade através de conexões recorrentes entre os neurônios. Um LSTM tem uma estrutura especial de neurônios chamada célula de memória. Estas células de memória têm a capacidade de armazenar informações ao longo de um tempo arbitrário. Três portões controlam as informações que fluem dentro e fora da célula de memória do neurônio: a entrada, a saída, e o portão de esquecimento. Cada portão no LSTM recebe a mesma entrada que o neurônio de entrada. Além disso, cada portão possui sua função de ativação (Gensler e Raabe, 2016).

Após analisar as curvas diárias de geração de energia, foi descoberto que as estações do ano e os tipos de clima têm uma grande influência na geração de energia elétrica de usinas FV, e as curvas de potência diárias de geração de energia FV sob diferentes tipos de clima mostram diferentes tendências. Portanto, o primeiro passo é agrupar diferentes tipos de tempo, utilizando o índice de irradiância. Então as redes LSTM são empregados para construir modelos de previsão para diferentes tipos de clima e para todos os climas apresentou o melhor desempenho em relação às demais redes testadas conforme mostrada na Tabela 1 (HE, 2018).

*Tabela 1 – Análise de diferentes redes neurais para distintas estações do ano.*

Estação	Modelo	MAPE [%]	RMSE[W]	MAE[W]
Primavera	<b>LSTM</b>	<b>22,30</b>	<b>598,91</b>	<b>309,42</b>
	ANN	31,90	874,03	422,58
	ELM	33,33	1050,95	497,00
Verão	<b>LSTM</b>	<b>79,48</b>	<b>1100,33</b>	<b>598,75</b>
	ANN	121,34	1318,74	693,25
	ELM	101,75	1187,93	651,77
Outono	<b>LSTM</b>	<b>32,40</b>	<b>571,29</b>	<b>281,09</b>
	ANN	51,68	1065,28	474,85
	ELM	49,94	1064,95	473,88
Inverno	<b>LSTM</b>	<b>23,71</b>	<b>481,69</b>	<b>223,77</b>
	ANN	35,24	728,27	319,04
	ELM	25,02	753,85	301,78

Fonte: HE et al (2018)

## 2.2 Referencial Teórico

Nessa seção são abordados os conceitos teóricos que são utilizados durante a apresentação desse trabalho como a influência das variáveis e o conceito de redes neurais recorrentes LSTM que será aplicado posteriormente na parte de metodologia.

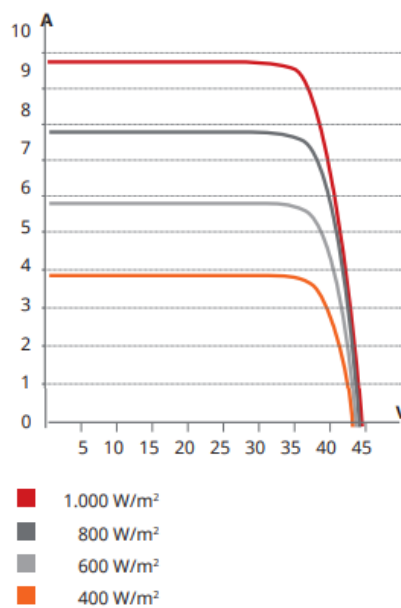
### 2.2.1 Influência das variáveis na geração FV

O impacto das variáveis climáticas na eficiência energética das células FV não são dependentes apenas da pureza ou dopagem do semicondutor, mas também de fatores não controláveis externos como a radiação, chuva, poeira, umidade, temperatura ambiente, velocidade do vento e outros fatores. Nessa seção é explicado qual o impacto de algumas variáveis de interesse na geração FV segundo outros trabalhos e documentação da empresa que produziu os módulos.

### 2.2.1.1 Influência da radiação solar

A corrente elétrica de um módulo FV está diretamente ligada à intensidade da radiação que incide sobre as células. A corrente elétrica é máxima quando há uma irradiância de  $1000\text{W/m}^2$  e temperatura de  $25^\circ\text{C}$  conforme especifica datasheets dos módulos. Nota-se que à medida que a irradiância solar diminui a corrente gerada pelo módulo cai quase que proporcionalmente, porém a tensão permanece quase que inalterada (Figura 5).

Figura 5 - Curva  $I \times V$  pela influência da irradiância.




Fonte: Datasheet Canadian Solar CS6U-325P

[<https://download.aldo.com.br/pdfprodutos/Produto34226IdArquivo4451.pdf>]

### 2.2.1.2 Influência da Temperatura Ambiente

A temperatura apresenta influência principalmente sobre a tensão que o módulo apresenta em seus terminais, reduzindo assim, a potência fornecida por ele. Em temperaturas mais baixas a tensão tende a ser maior enquanto em temperaturas maiores a tensão diminui conforme pode-se ver no Datasheet do módulo escolhido no estudo (Figura 6).

Figura 6 – Curva  $I \times V$  pela influência da temperatura



Fonte: Datasheet Canadian Solar CS6U-P

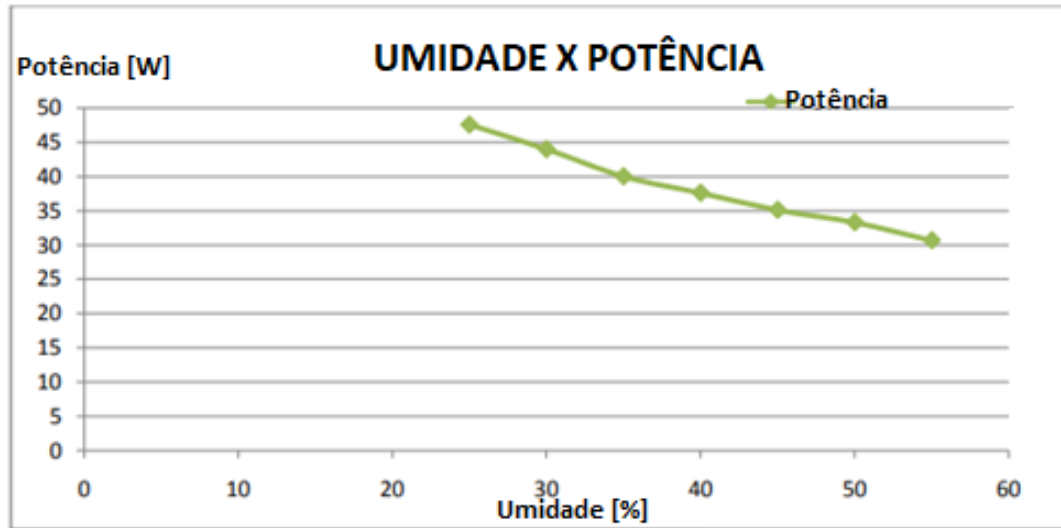
[<https://download.aldo.com.br/pdfprodutos/Produto34226IdArquivo4451.pdf>]

### 2.2.1.3 Influência da Umidade

A umidade relativa do ar faz referência a quantidade de partículas de água no ar que tem um determinado ambiente, e é dada em porcentagem. Quando a luz atinge uma gota de água no ar, três situações podem acontecer: refração, reflexão ou difração. Em qualquer desses casos, a quantidade de radiação direta que atinge os módulos é menor do que sem partículas de água no ar. A umidade altera a irradiância de forma não linear e a própria irradiância provoca pequenas variações no Voc de forma não linear e grandes variações no Isc linearmente (MEKHILEF. S., et. al. 2012).

Foi confirmado experimentalmente que a porcentagem de potência de saída pode cair em até uns 35,4% quando a umidade relativa aumenta de 25% pra 55%, para uma temperatura ambiente constante de 35°C típica em Karachi, Paquistão. O fator mais afetado pelo incremento da umidade é a corrente (situação similar com o aumento da nebulosidade) com um detrimento de até 32,37%, enquanto que a tensão baixa só 4,56% (Figura 7) (Panjwani & Narejo, 2014).

Figura 7 - Variação da potência de saída sob temperatura constante e aumento controlado na umidade relativa do ar



Fonte: PANJWANI; NAREJO. 2014.

#### 2.2.1.4 Influência da Velocidade do Vento

Na troca de calor entre os módulos FV e o ambiente que lhe rodeia, existem dos tipos de convecção que interatuam nos sistemas FV, os quais são a convecção natural e a convecção forçada, esta última, fortemente ligada com a velocidade do vento na vizinhança dos módulos. O vento leva com ele as moléculas quentes da superfície do módulo, tentando equilibrar a temperatura da vizinhança da superfície com a temperatura ambiente. É por isso que se recomenda realizar instalações de sistemas FV em coberturas de prédios ou casas, onde o passo do vento não seja interrompido (Andres, 2017).

O vento pode reduzir a temperatura dos módulos em até 1,45°C por cada m/s de velocidade do vento. Afirma-se que para velocidades do vento entre 1,2 m/s e 4 m/s a temperatura de trabalho do módulo pode diminuir entre 1,6°C e 6,5°C, para valores de irradiância entre 600 e 1000 W/m<sup>2</sup> (TamizhMani, 2003) e (Skoplaki et. al. (2008).

Principalmente em regiões com climas quentes em que os módulos operam em temperaturas maiores que 25°C torna-se benéfico uma alta velocidade do vento visto que essa diminui a temperatura do módulo e permite operar mais próximo da temperatura ideal que é a de STC (Condição padrão de teste) igual a 25°C.

## 2.2.2 Redes Neurais Recorrentes

Uma rede neural artificial é um modelo preditivo motivado pela forma como o cérebro funciona. Pense no cérebro como uma coleção de neurônios conectados. Cada neurônio olha para a saída de outros neurônios que o alimentam faz um cálculo e então ele dispara (se exceder algum limite) ou não (se não exceder). Redes neurais artificiais consistem de neurônios artificiais, que desenvolvem cálculos similares sobre suas entradas. Redes neurais podem resolver uma variedade de problemas como reconhecimento de padrões e elas são muito usadas em *deep learning* (Aprendizado profundo) (Grus, Joel. *Data Science do Zero*. Alta Books, 2016).

A rede normalmente é implementada utilizando componentes eletrônicos ou de simulação por programação digital. Para alcançar bom desempenho as redes neurais empregam uma interligação maciça de células computacionais chamadas de neurônios (Haykin, 2005).

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Pode-se, portanto, falar de algoritmos de aprendizagem como sendo estruturados. Pode-se identificar três classes de arquiteturas de redes neurais diferentes. Por trabalhar com séries temporais e com diversas variáveis, a arquitetura utilizada nesse trabalho é a rede neural recorrente com aprendizagem baseada em memória.

Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Uma rede recorrente pode consistir por exemplo de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios. A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos que resultam em um comportamento dinâmico não linear (Haykin, 2005).

### 2.2.2.1 LSTM (Long Short Term Memory)

O tempo constitui um ingrediente essencial do processo de aprendizagem. Independente da sua forma o tempo é uma entidade ordenada que é básica para muitas tarefas cognitivas encontradas na prática. É através da incorporação do tempo na operação de uma rede neural

que ela é capacitada a seguir variações estatísticas em processos não estacionários (Haykin, 2005).

Para que uma rede neural seja capaz de aprender de forma dinâmica é necessário que haja memória, sendo essa memória podendo ser dividida em curto prazo e longo prazo, a depender do tempo de retenção.

Para a previsão de ST a RNN mais utilizada é a Memória de Longo e Curto Prazo (LSTM) onde são capazes de captar a não linearidade e a aleatoriedade de dados de ST de forma mais eficaz do que uma RNA mais simples, bem como superar o problema de decadência do erro de retro propagação através da memória de blocos de LSTM, e assim mostra capacidades superiores para predição de ST com dependência temporal longa, (Manav Kaushik et al, 2020).

Uma célula LSTM é composta por além de entradas e saídas também função de ativação, produtos e as operações internas dentro dela se chamam de *gates*, sendo eles o *forgot gate*, *input gate*, *output gate* e *cell gate*.

O *Forgot Gate* é a componente do neurônio por esquecer uma informação retida no passado. O *Input e Cell Gate* são as componentes que decidem as informações novas de entrada que serão acrescentadas no neurônio de aprendizado. O *Cell Gate* corresponde às operações realizadas para a obtenção do que será propagado para a respectiva célula no próximo instante de tempo. Já a *Output Gate* é a componente responsável por processar a parte da informação que servirá como saída da rede.

Com a capacidade de memorizar dados históricos longos e determinar automaticamente o erro de decaimento da retropropagação, as RNA com arquitetura de LSTM atingem melhores resultados de previsão para problemas de ST em comparação aos modelos mais simples de RNA.

As redes neurais recorrentes comuns fazem uso das realimentações para armazenar representações de eventos recentes das entradas, o que recebe o nome de memória de curto prazo (*short-term memory*). Essa característica é bastante útil para diversos tipos de aplicações que não necessitam da influência tão longa dos estados passados. Existem algoritmos e arquiteturas de rede mais complexas que tentam prover um melhor aprendizado desses termos nas redes recorrentes comuns, porém o processo de seu treinamento é muito complexo e lento e ainda podem não funcionar tão bem (Hochreiter & Schmidhuber 1997).

Este tipo de rede recorrente tem a capacidade de reter informações de uma maior quantidade de entradas passadas (*long-term memory*) enquanto mantém a relevância de estados recentes maiores (Vilar, 2020).

### 2.2.3 Análises Gráficas do Erro

A análise dos erros é dada pela visualização de *boxplots*, esse tipo de gráfico estatístico é representado através de retângulos chamados de quartis com objetivo de fornecer informações sobre a variabilidades dos dados assim como os valores incomuns, os chamados *outliers* que podem impactar o cálculo de medidas simples como a média aritmética. O *Boxplot* utiliza cinco tipos de medidas para fazer a análise dos dados: Máximo, terceiro quartil (Q3), mediana, primeiro quartil (Q1) e mínimo. O conjunto desses dados possibilita verificar a dispersão e assimetria dos dados e assim verificar quais valores são extremos (Galvani e Luchiari, 2005).

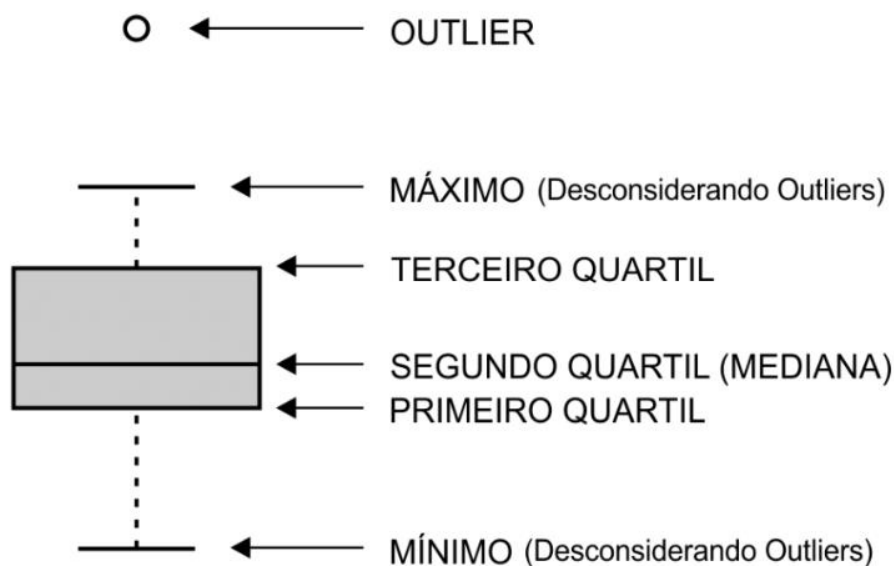
Os quartis representam os percentis 25, 50 e 75 que são respectivamente o primeiro quartil (Q1), mediana ou segundo quartil e o terceiro quartil (q3). A diferença entre os quartis também é uma medida importante chamado de desvio interquartílico ou IQR. Para entender o que é um *outlier* ou não são calculados limites utilizando as seguintes equações:

$$\text{Limite superior} = Q3 + 1.5 * (Q3 - Q1)$$

$$\text{Limite inferior} = Q1 - 1.5 * (Q3 - Q1)$$

Os valores menores que se enquadram abaixo do limite inferior ou superior ao limite superior são os *outliers*. As medidas estatísticas explicadas acima são mostradas graficamente conforme a Figura 8.

Figura 8 – Boxplot e suas medidas estatísticas



Fonte: Operdata (2019)



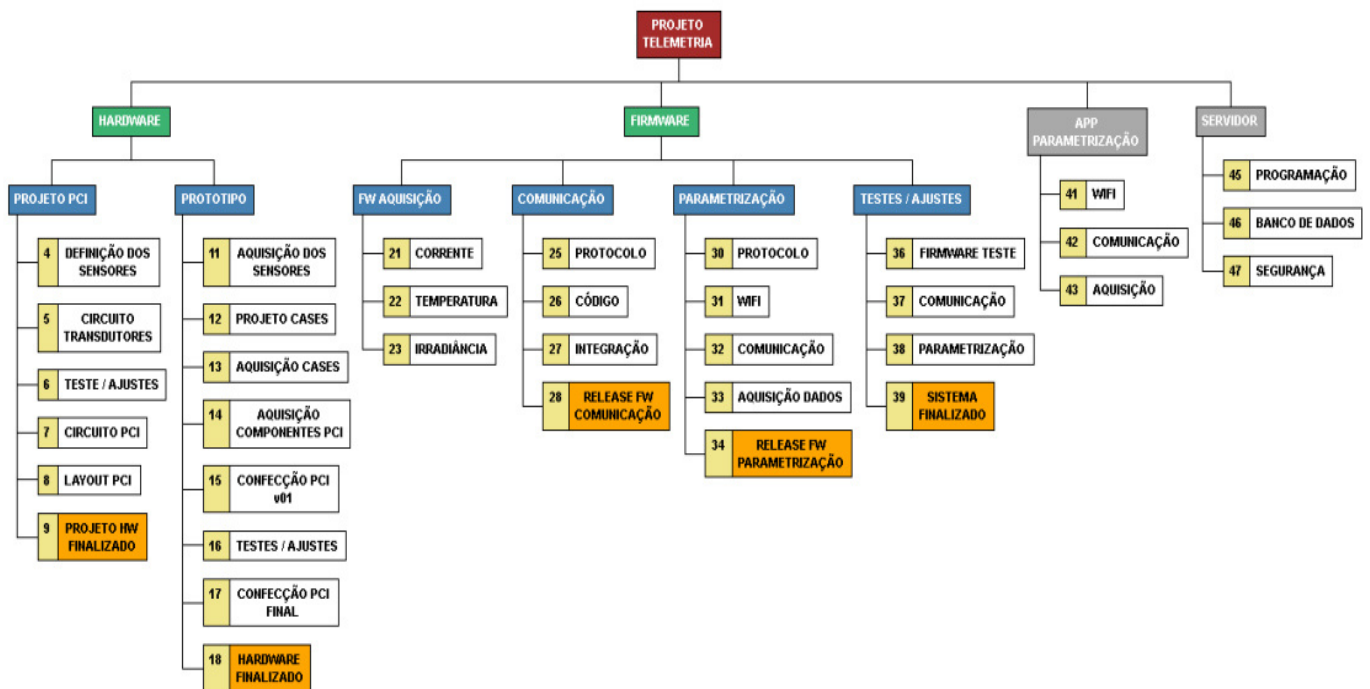
### 3 MATERIAIS E MÉTODOS

Neste capítulo é descrito o processo de monitoramento proposto na pesquisa e desenvolvimento bem como a programação das funções que o projeto desempenha, levantamento do material que foi utilizado, a montagem da placa de circuito impresso e da montagem física do projeto in loco.

#### 3.1 Desenvolvimento do sistema de Aquisição e programação no IDE Arduino.

Analisando os estudos preliminares mostrados no estado da arte, foram definidas quais variáveis seriam de interesse coletar para analisar seus valores em campo. Primeiramente foi definido o passo a passo que seria seguido de acordo com os objetivos a se alcançar, aplica-se uma metodologia setorizando o projeto em etapas e sua sequência de implementação sendo o primeiro passo a escolha dos sensores e por final a conexão com o servidor do banco de dados e sua segurança conforme mostrado na Figura 9. Então, foram selecionados os sensores fazendo pesquisas prévias sobre a sua atuação e seu modo de medição para adequar-se às especificações da pesquisa. Foram definidos 3 sensores para cada medição que foi executada: Temperatura e umidade ambiente, temperatura do módulo, correntes nas *strings*, irradiância e velocidade do vento, para isso foram definidos alguns sensores conforme mostrados na Tabela 2.

Figura 9: Estrutura analítica da Pesquisa



Fonte: Próprio Autor

Tabela 2 – Definição de sensores iniciais

<b>Sensores</b>					
	<b>Sensor Temp Módulo</b>	<b>Sensor Corrente</b>	<b>Sensor Ambien te</b>	<b>Piranômetro</b>	<b>Anemômetro</b>
<b>Sensor 1</b>	<b>DS18B20</b>	<b>INA219</b>	<b>DH11</b>	<b>SPEKTRON 210</b>	<b>SV10</b>
<b>Sensor 2</b>	<b>LMB5DC</b>	<b>ACS712</b>	<b>DHT22</b>	<b>SR10</b>	*
<b>Sensor 3</b>	<b>NTC 10K</b>	<b>WCS1800</b>	<b>DHT2</b>	<b>LP02</b>	*

Fonte: Próprio Autor

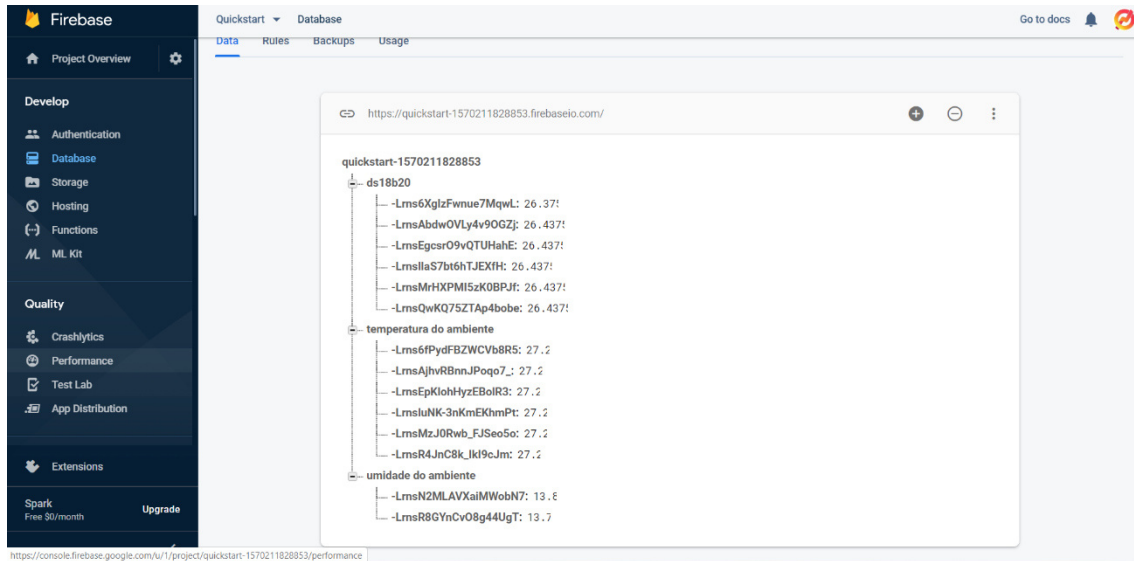
\*Dados não encontrados

Posteriormente foi iniciada a prototipação no Arduino UNO para familiarizar-se com sua IDE, sua linguagem e seus comandos, já que se assemelham com o processo de programação que futuramente seria utilizado no ESP8266. Após isso, foi solicitada a compra do ESP 8266 e do sensor de temperatura e umidade ambiente, para utilizar como ambiente de desenvolvimento, utilizando-o primordialmente para fazer conexão WI-FI e com isso conseguir enviar e receber dados do *Firestore*. Com a placa em mãos, foi inicializado o programa para a coleta dos dados, inicialmente apenas para um sensor de temperatura, e enviar para um banco de dados, com intuito de ter as informações remotamente e poder utilizá-los para os fins desejados.

Foi finalizada a prototipação da placa de desenvolvimento ESP8266 com dois sensores, o DHT12 (Sensor de umidade) e o DS18B20 (Sensor de Temperatura) para o envio de dados para o *Firestore*, uma parte do firmware foi completa (Figura 10).

Como meio de facilitar o monitoramento e visualização dos dados foi desenvolvida uma interface através da programação com a plataforma *ThingSpeak* para verificar mais facilmente a variação dos dados medidos. Tendo agora um banco de dados completo com o *Firestore* e o monitoramento *real-time* graficamente com o ThingSpeak (Figura 11).

Figura 10- Banco de dados do Firebase



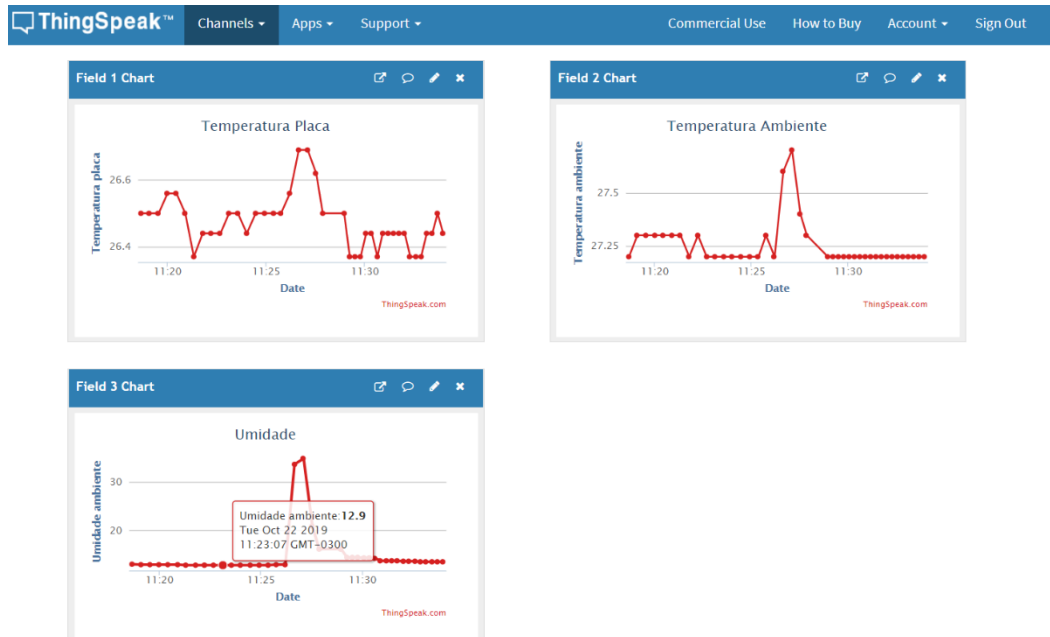
Fonte: Próprio Autor

A Figura 10 mostra a interface do *firebase*, no qual é um banco de dados que toda sua base é construída na infraestrutura do Google, sendo categorizado como um programa de banco de dados NoSQL, que armazena dados em documentos do tipo JSON que é **um arquivo que contém uma série de dados estruturados em formato texto e é utilizado para transferir informações entre sistemas**

O *Firestore* conta um grande conjunto de ferramentas de desenvolvimento. Destas, o ***Realtime Database*** e o ***Cloud Firestore*** podem armazenar dados estruturados em documentos e sincronizar os aplicativos correspondentes em milissegundos sempre que ocorre uma transformação de dados.

Na Figura 11 pode-se observar o funcionamento da plataforma o *ThingSpeak* sendo atualizada em tempo real, já que o *firebase* coleta os arquivos em formato JSON, utiliza-se o *ThingSpeak* para uma análise mais visual das variáveis medidas pelos sensores em campo.

Figura 11 – Monitoramento ao vivo da plataforma ThingSpeak.



Fonte: Próprio Autor

Após ter organizado o programa para gravar na EEPROM a cada minuto, e ter mantido o padrão de conexão com as plataformas do *FireBase* e *ThingSpeak* houve um foco maior para a estruturação do código, de um modo que facilite a leitura e a modificação, já sabendo que o código aumentará de extensão. Dessa maneira, está sendo criado algumas funções para que só acrescentemos quando for utilizado os outros equipamentos de medição como o Anemômetro. Posteriormente à familiarização do IDE do Arduino e um protótipo do código, foi feito à escolha dos sensores e componentes que seriam utilizados na pesquisa. Os seguintes sensores foram escolhidos devido às suas adequações ao projeto.

SHT20: Temperatura e umidade ambiente: Apresenta um encapsulamento que permite que o sensor fique exposto ao ar na usina, sem alterar sua performance.

DS18B20: Temperatura do módulo: Apresenta um encapsulamento para a colagem na parte anterior do módulo, além de apresentar um baixo custo em relação aos seus demais e uma precisão adequada.

WCS1800: Sensor de corrente contínua. Sensor que através de Efeito Hall consegue medir corrente contínua no intervalo que se adequa à nossa faixa de operação.

SV10: Anemômetro, sensor de velocidade do vento: Sensor que tem uma comunicação de 2 pinos de simples conexão com o ESP8266 Node MCU.

Piranômetro Spektron 210: Sensor de Irradiância. Comunicação analógica de 2 pinos que

permite a medição da irradiância na angulação em que o módulo está instalada.

Além disso foram definidos alguns componentes extras que precisaríamos para o sucesso do projeto, além de resistores e capacitores para adequar os sensores, também vimos necessidade de adquirir um conversor A/D (ADS1115), para suprir a necessidade de portas analógicas, precisaríamos de 2 para o sensor de corrente e do piranômetro, o NodeMcu apresenta apenas 1 porta analógica, além de aumentar a resolução da leitura. Além do conversor, compramos um regulador de tensão (LM2596) para adequar o nível de tensão de entrada das placas para a alimentação do circuito. A placa forneceria uma tensão de aproximadamente 30 V e precisaríamos passar para o nível de tensão entre 3.3 V e 5.5 V.

Então, para manter-se um padrão de organização foi executado um levantamento dos materiais (Figura 12) utilizados para a execução do projeto no total junto com seu Status de compra, local, preço, previsão de chegada entre outros dados importantes para a organização.

Figura 12: Levantamento dos materiais

Levantamento de Materiais					Legenda 1		Legenda 2	
Materiais	Qtde	Status	Local de compra	Comentário		Já disponível	Mestre	
ESP8266 - NODEMCU	x1		Autocore Robótica	Em mãos		A caminho	Sensores ou atuadores	
SHT20	x1		Usina Info	Em mãos		Ainda não foi feito o pedido	Periféricos principais	
SV10	x1		Usina Info	Em mãos			Componentes eletrônicos	
DS18B20	x2		Imagine Eletrônica	Em mãos			Componentes da placa	
WCS1800	x1		NeoWind	Em mãos			Case para a PCI	
PIRANÔMETRO	x1		NeoWind	NeoWind - Prazo 30/01 - 18/02			Cabos para conexão	
LM2596	X1		Usina Info	Em mãos				
RTC DS3231	X1		Usina Info	A caminho				
ADS 1115	X1		Autocore Robótica	Pedido feito				
Borne 2 vias	x4		Imagine Eletrônica	Em mãos				
Borne 3 vias	x4		Imagine Eletrônica	Em mãos				
Resistor 10k	x10		Imagine Eletrônica	Em mãos				
Resistor 1K	x6		Imagine Eletrônica	Em mãos				
Resistor 20k	x3		Imagine Eletrônica	Em mãos				
Capacitor 100pF	x3		Imagine Eletrônica	Em mãos				
Capacitor 2200uF	x2		Imagine Eletrônica	Em mãos				
LED	x6		Imagine Eletrônica	Em mãos				
Fusível 1A e 2A	x20 10-10		Usina Info	Em mãos				
Porta fusível	x2		Usina Info	Em mãos				
Fenolite fibra vidro	x1		Eletrônica Circuitos	Em mãos				
Percloroeto de ferro	x1		Eletrônica Circuitos	Em mãos				
Caixa Steck 17x14	x1		Leroy Merlin	Falta pegar				
Cabo manga 3 vias	?m		Eletrônica Circuitos	Em mãos				

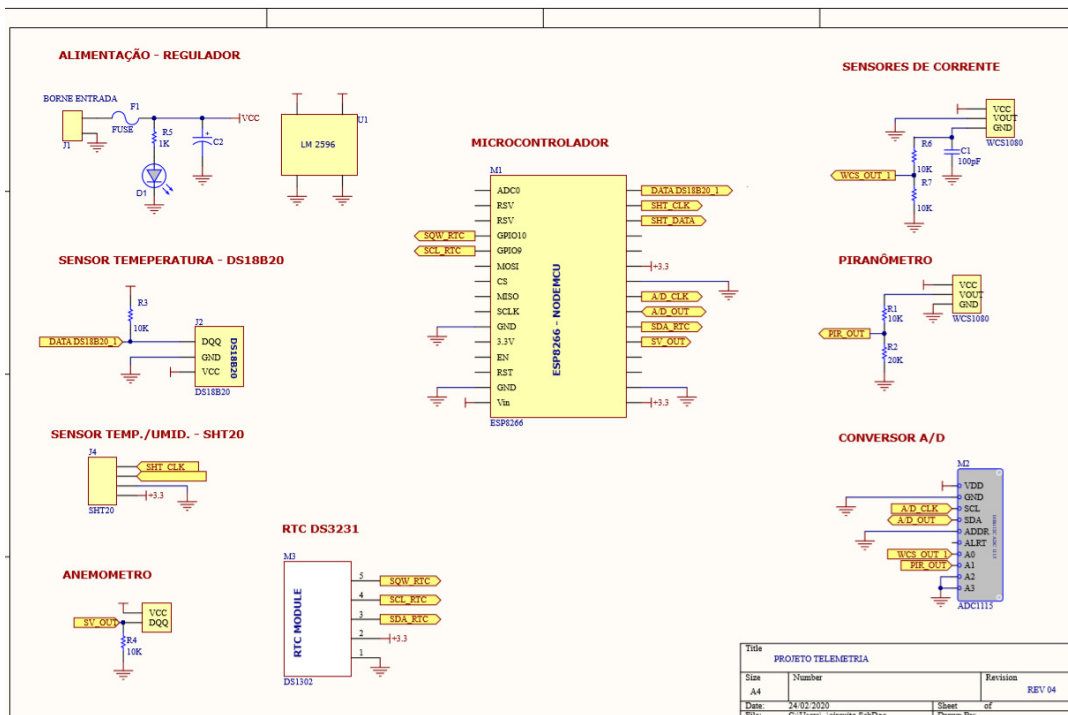
Fonte: Próprio Autor

### 3.2 Montagem da Placa de Circuito Impresso

Após a definição e compra dos sensores foi iniciada a montagem da placa de circuito impresso (PCI) no Software de confecção de placas (*Altium*). Posteriormente aos passos da montagem da placa, foi marcado quais os pinos utilizados para o NodeMCU ESP8266 e terminou-se o projeto no *Altium* (Figura 13 à Figura 15).


A Figura 13 representa a visão esquemática do projeto no software *Altium* que emulará a placa de circuito impresso que será necessário o confeccionamento. Na visão esquemática temos todos os elementos utilizados no projeto e suas conexões. Cada *layer* daquela conectada no Microcontrolador principal corresponde a uma conexão com os outros equipamentos. Por exemplo, no anemômetro (SV-10) tem-se a saída dele como SV\_OUT e no pino 16 do microcontrolador (ESP-8266) observa-se a mesma indicação do SV\_OUT, o que representa que aquele pino do anemômetro irá ser conectado naquele pino do microcontrolador. A mesma lógica se aplica aos demais componentes e pinos. O desenho das trilhas finais da placa e os componentes utilizados são representados respectivamente pelas Figuras 14 e 15. Em seguida do projeto todo montado no Software, utilizou-se os componentes da placa para termina-la a versão física dela, feita na prensa conforme é possível ver na Figura 16.

Figura 13: Visão do Esquemático do projeto da pesquisa:



Fonte: Próprio Autor

Figura 14: Visão das trilhas da placa




Fonte: Próprio Autor

Figura 15 :Componentes utilizados para a execução do Projeto da pesquisa no Altium

Comment	Description	Designator	Footprint	LibRef	Quantity
Cap	Capacitor	C1	CAP-CER-100	Cap	1
CAPACITOR ELET.	CAPACITOR ELETROLÍTICO	C2	CAP-ELT-200	CAPACITOR ELET.	1
LED	LED	D1	LED 3MM	LED	1
FUSE	Polyswitch, 0.47 ohms Max, 40 A Max, 72V	F1	FUSE2.5	FUSE	1
BORNE ENTRADA	Connector SIP	J1	BORNE_2VIAS_P	CON2	1
DS18B20	Connector	J2	BORNE_3VIAS_P	DS18B20	1
SV10	Header, 2-Pin	J3	BORNE_2VIAS_P	Header 2	1
SHT20	Sensor de temperatura	J4	BORNE_4VIAS_P	Header 4	1
WCS1080	Header, 3-Pin	J5, J6	BORNE_3VIAS_P	Header 3	2
ESP8266		M1	NODEMCU	ESP8266 NODEMCU	1
ADC1115		M2	Conversor AD1115	ADC1115	1
DS1302		M3	SIP5	DS3231-MODULO	1
Res1	Resistor	R1, R2, R3, R4, R5, R6, R7	AXIAL-0.3	Res1	7
LM2596		U1	LM2596	LM2596	1

Fonte: Próprio Autor

Figura 16: Placa de Circuito Impresso



Fonte: Próprio Autor

Como mostrado na Figura 16, foi feito alguns ajustes para a execução do projeto de pesquisa, como a utilização de capacitores para não haver carga e descarga imediata do sistema podendo provocar surtos elétricos, fusíveis para proporcionar ao sistema uma certa segurança, além disso, os bornes de entrada para facilitar a conexão dos sensores e atuadores na placa, leds que facilite a visualização do funcionamento do sistema, resistores para controlar o nível de tensão e do nível de corrente do sistema, além de barra de pinos, tanto para a conexão do ADS1115 (conversor analógico – digital), como para acesso de diferentes níveis de tensão (Pino vermelho 12V, Pino amarelo 5V). Todas as conexões foram feitas pela parte traseira da placa através das conexões já estabelecidas pelo *Software Altium*.

### 3.3 Utilização dos sensores para teste e conexão ao banco de dados.

Com a placa em mãos foi possível iniciar novas atualizações no firmware para acrescentar-se o que estava a faltar enquanto não se tinha ainda os componentes em mãos. O primeiro passo foi utilizar os novos sensores de temperatura ambiente e temperatura do módulo e implementar um código que calculasse a diferença entre as médias das duas, um dado importante para fazer aferições sobre a diferença entre as temperaturas médias durante o dia e como isso afetará a geração de energia. Acrescentou-se esse dado na plataforma de análise de dados virtualmente (*ThingSpeak*).

Posteriormente testou-se todos os sensores para a implementação no código com intuito de manter todos conectados de uma maneira síncrona com o código. Todos os sensores ou



atuadores foram testados se funcionaram de acordo. Então, começou-se a implementar um a um no código, o primeiro foi o RTC (*Real-Timed-Clock*) para a aferição do tempo a qualquer momento nos códigos e manter uma precisão mais elevada, o outro sensor a ser implementado no código foi o SHT20 (Sensor de umidade e temperatura ambiente), aumentando a precisão em relação ao sensor anteriormente utilizado (DHT12). O próximo sensor a ser implementado seria o Piranômetro.

Durante os primeiros versionamentos do código do projeto foi identificado um erro na colocação dos pinos nas placas, foram conectados os pinos CLK e SDA de um sensor que utiliza como protocolo de comunicação I2C, em pinos do ESP8266 que não executariam tais funções, coletamos a placa para averiguar o erro e ajustar os pinos.

Ajustando a placa para o aceite de todos os sensores e componentes das placas foi possível retornar para o código visando ajustar e juntar todos os passos já feitos previamente para a finalização da revisão final do código do projeto. Devido ao código apresentar uma quantidade relevante de linhas, foi definido em reunião que dividiria o código em etapas a se cumprir referente ao passo a passo do projeto, ou seja, foi apresentado uma repartição do código em 5: Sensores, Timer e RTC, EEPROM, Conexão WIFI e conexão com servidor. O intuito dessa divisão foi a execução individualmente de cada trecho do código para, apenas, no final integrar todas numa 6ª divisão chamada Integração. Assim seria possível identificar o passo a passo do código e encontrar erros mais fáceis de serem ajustados, evitando a montagem do zero de um código extenso e era possível montar as versões de cada código, tal qual se fosse implementar uma nova funcionalidade criariam outra versão para não atrapalhar o que já foi feito.


No trabalho para captação de dados, nada mais importante que os sensores, então o primeiro passo foi a criação de funções para coletar os dados coletados pelos sensores em determinado tempo, para isso foi criado um *struct*, uma estrutura de linguagem que é uma lista de dados compostas agrupadas sob um nome de bloco de memória. Então, em vez de criar várias funções e variáveis separadas, criou-se um *struct* para agrupar todas as variáveis dos sensores e periféricos, como o ADS1115, com isso já feito foi implementada a função para a leitura dos dados dos sensores. Para o RTC, DS18B20 e SHT20 não se fez necessário executar nenhuma alteração, apenas chamar a função que leria o dado. Já para o sensor de corrente e irradiância, já que se tratam de grandezas analógicas, teve que ser feita uma conexão com o ADS1115 para colher os dados. O ESP8266 utilizado nesse trabalho apresenta uma porta analógica, mas não foi utilizado pelo motivo de resolução, enquanto o ADS1115 apresenta uma resolução de 16bits

o AD interno do ESP-8266 nos retorna uma resolução de 10bits.

Para o anemômetro, teve que ser feito uma lógica para captar o seu dado, já que o dado retornado por ele é dependente de um sistema de pulsos por tempo (Figura 17), no qual tem-se um ímã ligado ao eixo do anemômetro e um interruptor de lâminas, em situações normais as lâminas estão separadas, logo em circuito aberto, quando um ímã se aproxima das lâminas, fazem com que se magnetizem e com isso se atraíam, com isso o circuito se fecha e é permitida a passagem de corrente. Para o anemômetro, a cada volta que o eixo executa, o ímã passa pelo interruptor e permite a corrente elétrica, ou seja, basta medirmos os pulsos elétricos fornecidos pelo anemômetro para captar a velocidade do vento através de uma fórmula de conversão já dada pelo fabricante.

Após o entendimento desse princípio de funcionamento, foi possível codificá-lo para o entendimento do ESP, então foram feitas rotinas para limitar o tempo e nesse tempo contar os pulsos elétricos fornecido pelo Anemômetro através de interrupções do pino conectado. Após testar todos os sensores, já teríamos a primeira parte completa, a captação de dados.

Figura 17 – Funcionamento elétrico do Anemômetro



Fonte: Anemômetro – Arduíno Usina Info

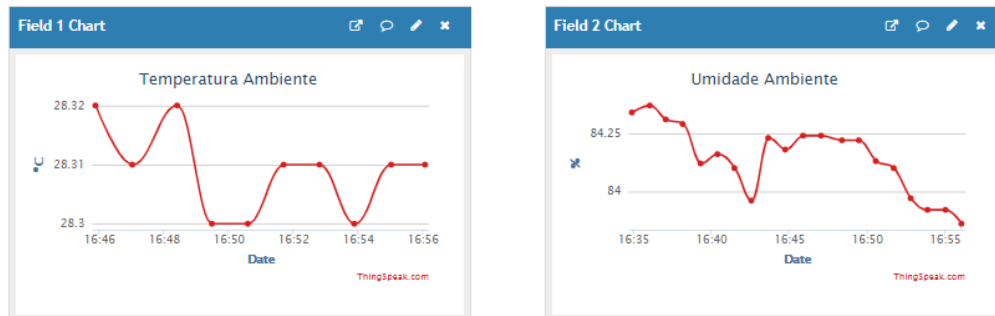
Posteriormente ajustou-se a parte do Timer e RTC para o acompanhamento em tempo real dos sensores, apenas adicionou-se as funções já criadas anteriormente, limitando o timer em valores baseado no intervalo que seria adequado que as funções fossem executadas, sempre acompanhado pelo RTC. Para meios de facilitar a análise do banco de dados foi solicitado que o tempo não fosse dado em tempo real e sim em *UnixTime* que é um sistema de acompanhamento definido como o número de segundos passados desde 1 de Janeiro de 1970, sem considerar questões especiais como anos bissextos, é utilizado para facilitar a leitura pelo

computador que enquanto em data comum teria que ser avaliado 6 campos (Ano, mês, dia, hora, minuto e segundo) com o Unix TimeStamp ele simplesmente analisa um valor inteiro que pode ser passado facilmente para binário para a leitura da máquina. Foi ajustado o RTC para a leitura da máquina, tendo terminado esse passo do Timer.

Para a organização de EEPROM utilizou-se um conceito novo para a organização dos dados, a implementação de uma lista encadeada circular que se trata de uma lista de dados que sobrescreve ao chegar em seu limite sempre de forma circular, ou seja, quando a lista chega na sua última posição ela sobrescreve a posição mais antiga, como mostra a lógica na Figura 18 encontrada na seção dos anexos. Foi definido o tamanho da fila para 15 posições, na qual julgou-se o bastante para abranger os últimos dados gravados, já que só foi pensado em utilizar a lista para gravar na EEPROM quando a conexão com a internet tiver instável. Além disso, foi feita uma adaptação para a EEPROM conseguir contemplar os dados do formato que eles eram coletados (float), ou seja, enfrentamos um problema inicialmente para a EEPROM armazenar valores decimais, para solucionar tal fato, separamos para cada sensor 4 posições da EEPROM, sendo bastante para armazenar qualquer valor decimal. Após a gravação dos valores corretamente, precisaríamos uma função de descarregamento dos dados, que foi feito praticamente de modo análogo da função de gravação dos dados.

Próximo passo seria adaptar à conexão WIFI para os fins que seria desejado, apenas teve-se que transformar à conexão em condicionais para o código seguir os passos em caso de desconexão. Para alcançar o máximo de performance do código foi pensado que em, caso a internet esteja conectada, os dados seriam enviados normalmente para os servidores para não prejudicar a memória EEPROM que é limitada para o ESP8266, caso a internet caia, seria acionada a lista encadeada e gravaria os valores medidos na fila para que quando a internet tivesse novamente a conexão estável seja possível enviar os dados gravados enquanto não estava conectado, assim evitando a perda de dados devido à instabilidade da conexão. Quando a conexão com a internet não estiver regular, foi aumentado o período de leitura do sensor, para que se prolongar para voltar, mesmo assim fosse possível captar os dados, mesmo que com um intervalo maior entre eles.

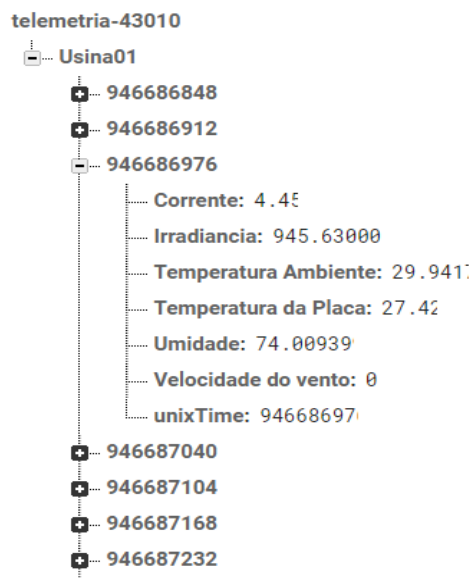
Finalmente, o último passo foi a conexão com os servidores, *FireBase* para Banco de Dados, e *ThingSpeak* para a visualização dos dados (Figura 19). Para o *ThingSpeak*, bastou tornar possível a conexão do API no código e enviar os valores para os campos de visualização, apresentando a seguinte interface

Figura 19 – Aplicação *ThingSpeak*

Fonte: Próprio Autor

Para o FireBase, teve-se que organizar o banco de dados (Figura 20) para facilitar a captação de dados para meios futuros, então fez-se necessário criar cada pasta e subpasta para armazenar os dados corretamente, para isso foi preciso criar variáveis que fossem capazes de armazenar os nomes das pastas. Então foi definido que para o nome da pasta seria o nome da usina, que caso o projeto seja produzido em massa tem-se um banco de dados amplo e dentro da pasta temos o valor em UnixTime para ser possível acompanhar o tempo em que os dados dos sensores foi coletado. Além disso, foi colocado uma rotina para ser possível alterar especificações como o período de leitura e o relógio de forma remota, estabeleceu-se uma variável chamada cmd que de acordo com o valor ele executa tal função. Por exemplo, 101 muda o período da leitura do sensor e 102 para mudar o relógio. Assim, o banco de dados fica organizado e possível ser alterado remotamente (Figura 21).

Figura 20 – Ilustração do banco de dados



Fonte: Próprio Autor

Figura 21 – Ilustração com o comando de alteração remota

```

946700800
Corrente: 4.45
Irradiancia: 945.63000
Temperatura Ambiente: 28.31139
Temperatura da Placa: 27.42
Umidade: 83.85900
Velocidade do vento: 0
unixTime: 946700800
cmd: 101
cmdDado: 20
  
```

Fonte: Próprio Autor

Posteriormente foi integrado tudo em um único código e já seria possível colocar em campo para testes, devido às impossibilidades devido ao COVID-19 não foi possível colocar in loco e então seria testado em casa durante uma semana, somente para avaliar o desempenho e robustez do projeto com algumas variáveis.


### 3.4 Instalação do sistema no local.

Após toda a montagem remota de equipamentos e programação ter sido concluída foi iniciado o planejamento da montagem física na Usina. Os equipamentos utilizados na usina são:

- Módulos: Canadian Solar CS6U-325P
- Inversor: ABB TRIO-50-TL-OUTD

De acordo com a planta da Usina FV foi desenhada a localização dos sensores e da estação meteorológica de modo que possamos levantar os demais materiais para que a instalação seja feita de maneira adequada e segura para o sistema (Figura 22).


Figura 22 - Desenho da instalação do Sistema



Fonte: Próprio Autor

De acordo com as dimensões da Usina, obtida pela planta (Figura 23) foi possível ser levantada a metragem dos cabos necessários e após planejar decidiu-se o que seria necessário para a instalação da estação e dos sensores de corrente, além da definição de como seria possível colar o sensor de temperatura colado na parte inferior do módulo. Com todos os materiais levantados, a última atualização do levantamento dos materiais (Figura 24) foi encerrada.

Figura 23 - Dimensões da planta da Usina FV



Fonte: Próprio Autor

Figura 24 – Levantamento de Materiais

Levantamento de Materiais				
Materiais	Qtde	Status	Local de compra	Comentário
ESP8266 - NODEMCU	x1		Autocore Robótica	Em mãos
SHT20	x1		Usina Info	Em mãos
SV10	x1		Usina Info	Em mãos
WCS1800	x1		NeoWind	Em mãos
PIRANÔMETRO	x1		NeoWind	Em mãos
LM2596	X1		Usina Info	Em mãos
RTC DS3231	X1		Usina Info	Em mãos
ADS 1115	X1		Autocore Robótica	Em mãos
Borne 2 vias	x4		Imagine Eletrônica	Em mãos
Borne 3 vias	x4		Imagine Eletrônica	Em mãos
Resistor 10k	x10		Imagine Eletrônica	Em mãos
Resistor 1K	x6		Imagine Eletrônica	Em mãos
Resistor 20k	x3		Imagine Eletrônica	Em mãos
Capacitor 100pF	x3		Imagine Eletrônica	Em mãos
Capacitor 2200uF	x2		Imagine Eletrônica	Em mãos
LED	x6		Imagine Eletrônica	Em mãos
Fusível 1A e 2A	x20 10-10		Usina Info	Em mãos
Porta fusível	x2		Usina Info	Em mãos
Fenolite fibra vidro	x1		Eletrônica Circuitos	Em mãos
Percloroto de ferro	x1		Eletrônica Circuitos	Em mãos
Caixa Steck 17x14	x1		Leroy Merlin	Em mãos
Cabo manga 3 vias	41m		Eletrônica Circuitos	Em mãos
Cabo PP 2 x 1,5	18m		Eletrônica Circuitos	Em mãos
Suporte fusível de rabicho	x1		Eletrônica Circuitos	Em mãos
Conector de painel Solar (MCT-4)	x3		NeoWind	Em mãos
Tripé	x1		Ibyte	Em mãos
Silver Tape	x1		Leroy Merlin	Em mãos
DS18B20	x3		Autocore Robótica	Em mãos
Case sensor corrente	x3		Carmehil	Em mãos
Silicone alta temperatura	x1		Leroy Merlin	Em mãos
Prensa cabos	x8		Leroy Merlin/Carmehil	Em mãos

Fonte: Próprio Autor

Após o planejamento concluído foi feita uma visita presencial para verificar uns pontos importantes para a instalação e tirado algumas fotos para facilitar a instalação futuramente.

As Figuras 25 até a 28 que são encontradas na seção dos anexos apresentam os registros tirados na visita à usina de Cascavel para analisar os seguintes pontos:

Ponto de Conexão 220V (Figura 27).

Ponto de conexão Wi-Fi (Figura 26).

Local de Fixação do Módulo de alimentação (Figura 19).

Local de Fixação da instalação (Figura 28).

Estabilidade da Estrutura (Figura 28).

Local de fixação do sensor de corrente (Figura 25).

Comprimento dos cabos de medição de corrente


Fixação dos cabos

Comprimento dos cabos sensor de temperatura

Após a identificação de todos os pontos necessários para a instalação, fez-se necessária

a preparação do case para a inclusão do sensor de corrente através do cabeamento das strings do sistema utilizado. Foi feita uma extensão utilizando cabos do tipo MCT-4 (especificação da usina), o sensor de corrente utilizado é não-invasivo, porém como os cabos já estavam conectados em série nas strings, foi feito uma crimpagem de novos cabos de dimensões pequenas para tornar-se possível a inserção deles diretamente no sistema sem interferir no sistema que estava em funcionamento. Além disso, para não diminuir a influência externa, os sensores de corrente ficarão dentro de uma caixa hermética com utilização de prensa-cabos (Figura 29).

Figura 29 – Caixa hermética dos sensores de corrente



Fonte; Próprio Autor

Feitos os ajustes foi possível a instalação do equipamento em campo. Para facilitar a instalação foi necessário marcar 2 visitas à usina para trabalharmos com mais cautela e com mais tempo de testes. Para a visita 01 foi feito a instalação em campo de todos os sensores e seus testes com um computador pessoal visando identificar algum erro imediato, além da tentativa de deixar os sensores de temperaturas colados no módulo apenas utilizando o silicone de vedação, para que na visita 02 seja possível deixar *in loco* todo o equipamento já corrigido



suas falhas.

A primeira tentativa foi testar a estação montada previamente em campo para identificar os valores e se estavam de acordo com a normalidade (Figura 30 e 31).

Figura 30 – Fixação da Estação meteorológica em campo



Fonte: Próprio Autor

Figura 31- Estação Meteorológica



Fonte: Próprio Autor

Escolhido o local de instalação da estação, foi possível medir o cabo manga utilizado e começar a colar os sensores de temperatura na parte inferior dos módulos. Foram colocados 3 sensores de temperatura em ação, um sensor no primeiro painel, um no painel central e um no último. A colagem dos sensores foi feita através do uso de uma aderente a base de silicone adaptado a altas temperaturas, além disso foi utilizada uma abraçadeira de duas faces para ajudar na fixação além de colocar fita isolante para manter o sensor colado no painel até a secagem do silicone

Os sensores foram instalados na parte central de cada painel para padronizar as medições, já que é sabido que o painel apresenta alguns pontos mais quentes que outros, por exemplo, se fosse posto um sensor na parte central do painel e outro nas partes laterais seriam medidos valores diferentes, normalmente na parte central do painel há uma temperatura um pouco mais elevada. Por isso, foi colocado todos os sensores na mesma localização nos diferentes painéis (Figura 32).

Figura 32 – Maneira de fixação Sensor de Temperatura



Fonte: Próprio Autor

Após a fixação dos sensores de temperatura foi executada a instalação dos sensores de corrente, como é usado sobre uma tensão de cerca de 800 V foi necessária a utilização de EPI's para abrir o circuito e cortar a corrente através dos cabos. A fixação do sensor de corrente foi feita através da utilização de cabos MCT-4 onde foi aberto o circuito (Figura 33) e montado através de uma extensão para apenas conectar o sensor, no estilo *plug and play*, para ser o menos invasivo possível e não afetar o desempenho da usina (Figura 34).

Figura 33 – Abertura do Circuito das Strings



Fonte: Próprio Autor

Figura 34 – Sensores *plug and play* de Corrente instalados



Fonte: Próprio Autor

Por último na primeira visita foi feita a soldagem dos cabos mangas com os sensores de temperatura para ser feito o teste *in loco* através do uso do computador pessoal (Figura 35).

Figura 35 – Soldagem do Sensor de temperatura e cabo manga 3 vias



Fonte: Próprio Autor


Posteriormente foi necessária a volta à usina para verificar os sensores de temperatura e colocá-los todos em funcionamento para o acompanhamento remoto. Foi posto também um módulo de reinício remoto *sonoff* (Figura 36) para ser possível o manuseio da estação em locais distantes da usina, utilizando apenas a conexão Wi-Fi do módulo é possível desligar e ligar a fonte que mantém a estação ligada. Ferramenta importante para conserto de algum problema que possa acontecer com o módulo, de modo que possamos verificar se é um problema físico ou no *software*, com intuito de evitar deslocamentos desnecessários.

Todavia, após a instalação foram-se feitos testes e foi constatada uma irregularidade nos dados dos sensores de temperatura (Figura 37), devido a alguns possíveis ruídos ocasionados pelo comprimento do cabo que interliga os 3 sensores de temperatura, causado fisicamente pelo aumento da queda de tensão entre os pontos.

Figura 36 - Módulo *Sonoff*

Fonte: Próprio Autor

Figura 37 – Dados enviados sensor de temperatura 03




Fonte: Próprio Autor

Por isso, foi necessária a ida mais uma vez na usina de modo a consertar tal problema com a utilização de um filtro passa baixa. O filtro passa baixa é composto por um circuito RC-série, em que a tensão de saída é a tensão sobre o capacitor. Para ondas com frequências baixas,

como é o caso do sistema utilizado, a reatância capacitiva assume valores de grandezas semelhantes ao valor da resistência, dessa maneira a tensão de saída será mantido igual à tensão de entrada. Dessa maneira, o filtro permite a passagem de sinais com frequências menores e atenua as de frequências maiores, por isso chamado de filtro passa-baixa (Figura 38).

Figura 38 – Filtro Passa-Baixa



Fonte: Boylestad, 1984

Assim, será colocado um filtro passa-baixa de modo que filtre o sinal de menores frequências para que não ocorra mais o erro de ruído entre os locais instalados dos sensores.

Na quinta ida a campo foi detectado um erro no *reed switch* do anemômetro além da inserção do filtro passa-baixa no sistema como meio de resolver o possível erro ocasionado por ruídos, visto na hora, foi pensado que o filtro com um capacitor de 10nF teria resolvido o problema, porém ao analisar pela ferramenta de análise dos dados foi percebido que o ruído havia apenas diminuído, porém ainda existia. Analisando os dados dos sensores de temperatura junto com os dados inexistentes do anemômetro, fez-se necessário mais uma ida na usina como meio de resolver a inconstância dos dados dos sensores de temperatura e ativar novamente a coleta dos dados do anemômetro com a troca do *reed switch* (Figura 39).

Para manter fixados os sensores de temperatura e manter isolado cada sensor, foi imaginado que colocando cada sensor em um barramento diferente do ESP8266 manteria mais constante os dados e diminuiria a presença de ruídos. Para isso foi necessária a compra de um cabo-manga de 4 vias com malha para a isolação de cada sensor que está sendo utilizado, além da compra de um novo *Reed Switch*.

Figura 39- *Reed Switch* do anemômetro que precisou ser trocado



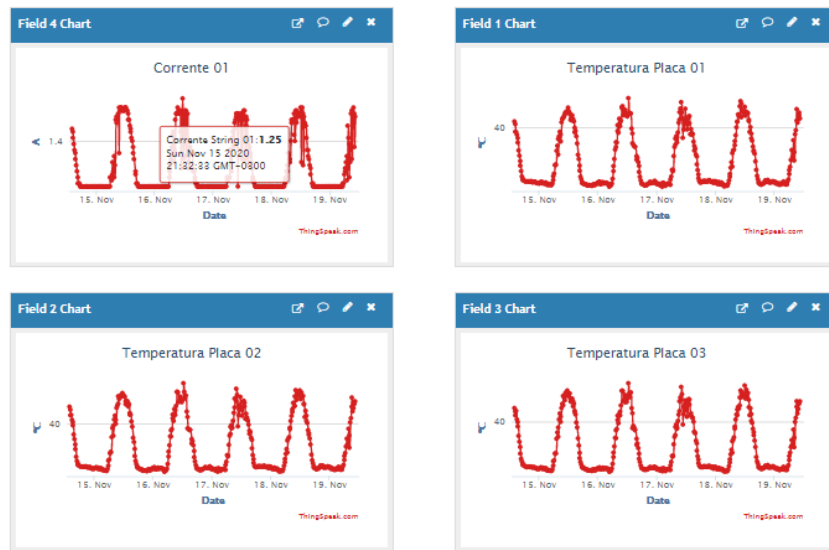
Fonte: Próprio Autor

Para a sexta visita em campo dos pesquisadores foram feitas as mudanças necessárias, como a troca do *reed switch* e isolamento de cada sensor em seu pino no ESP, porém não houve uma resposta adequada do sistema de forma imediata, para evitar um possível retorno sem o projeto estar funcional foi imaginado que poderia ser a presença de um resistor de  $4k7 \Omega$  que aumentaria a impedância do sistema e por isso o sinal de dado estivesse sendo interrompido. Foi feita a troca do resistor de  $4k7 \Omega$  por um resistor de  $1k \Omega$  e o problema foi resolvido.

Após a resolução do ruído ocasionado pelos resistores, foi possível finalmente analisar as variáveis de corrente e temperatura da placa através da plataforma de visualização de dados, sendo possível também observar a correlação entre algumas variáveis (Figura 40 e 41).

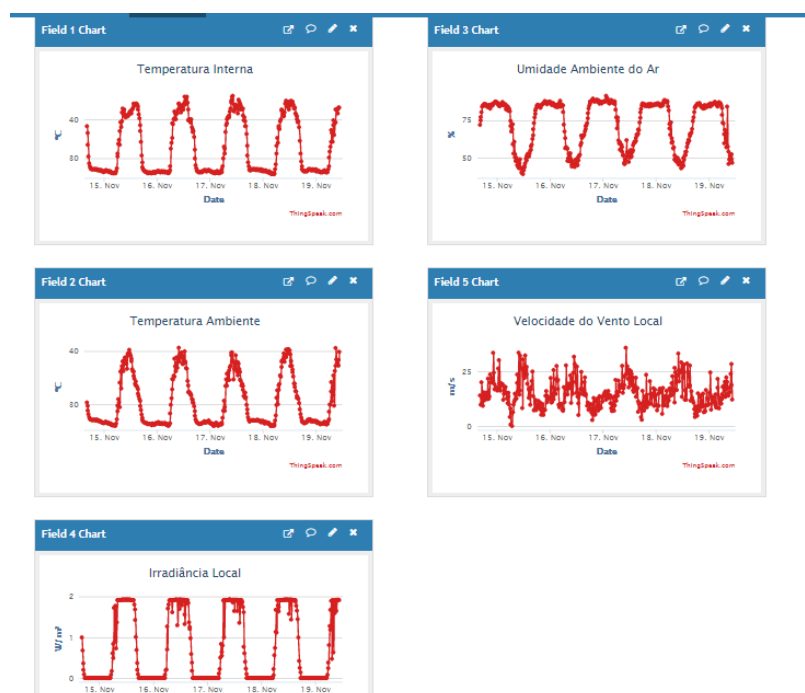


Figura 40 – ThingSpeak com as variáveis Temperatura e Corrente



Fonte: Próprio Autor (plataforma *ThingSpeak*)

Figura 41 – ThingSpeak com as variáveis ambiente



Fonte: Próprio Autor (plataforma *ThingSpeak*)

Já é possível com esses dados analisar uma correlação entre as variáveis, para a finalização do projeto basta apenas a atualização do novo sensor de temperatura que será utilizado de uma maneira diferente do que está usado hoje, por isso será necessária a alteração na placa, além da montagem de uma nova placa de circuito impresso para colocar em campo, visto que foram feitas alterações significativas na placa durante a fase de prototipação.

Por fim, foi instalada finalmente a nova placa com os novos sensores em campo,

havendo apenas um erro que foi necessário ajuste que estava relacionado ao sensor de corrente que a relação via *firmware* estava errada, por isso foi necessário fazer algum ajuste e conectar todos os sensores. Caso necessário é possível também instalar dois sensores de irradiação de forma concomitante, caso se faça necessário no projeto analisar a irradiação direta sobre o módulo, ou seja, inclinada a 15° e a irradiação horizontal. No caso não foi necessário trabalhar com os dois sensores, porém a placa foi feita para comportá-los.

Com isso, o projeto pôde ser finalizado com êxito, com todos os sensores medindo valores factíveis. Para o anemômetro, foi feita aferição via anemômetro digital, para os sensores de temperatura também foi utilizado um termômetro digital, para os demais sensores foi feita da mesma maneira, utilizando outro sensor como referência e fazendo a comparação.

Dessa maneira, tem-se medições de temperatura ambiente, sensação térmica, umidade ambiente, irradiação local, temperatura do módulo localizada na *string* no início e no meio da mesa de painéis, corrente nas duas *strings*, temperatura interna do microcontrolador, velocidade do vento. Todos esses parâmetros sendo monitorados a cada 15 minutos via software de visualização de dados. A Figura 42 mostra a estação fixa da usina após a instalação.

Figura 42 – Estação em funcionamento executando testes locais



Fonte: Próprio Autor

Foi executado o projeto de maneira que seja acessível executar testes locais com intervalos de tempo menores para que facilite qualquer adaptação do código caso se faça necessário, foi utilizado a plataforma do Arduino para verificar os dados medidos a cada minuto, a Figura 43 mostra o monitoramento local das variáveis que recebia os dados a cada 15 minutos.

Figura 43 – Monitoramento local das variáveis

```

COM3
tempPanel_3: 33.94
tempInterna: 32.75
TempAmbiente_pt100: 29.69
-----
Tempo: 1608058927
TempAmbiente_sht20: 34.02
Umidade: 59.21
Irradiancia: 301.99
velocVento: 0.90
Corrente_1: 19.68
Corrente_2: 19.67
tempPanel_1: 32.88
tempPanel_2: 36.94
tempPanel_3: 34.00
tempInterna: 32.50
TempAmbiente_pt100: 29.63
-----
Tempo: 1608058987
TempAmbiente_sht20: 34.06
Umidade: 59.48
Irradiancia: 297.12
velocVento: 1.19
Corrente_1: 19.66
Corrente_2: 19.65
tempPanel_1: 32.75
tempPanel_2: 36.56
tempPanel_3: 33.81
tempInterna: 32.50
TempAmbiente_pt100: 29.37
-----
Comando Recebido: 0
Dado enviado Firebase
Dado01 enviado para o Thingspeak
Dado02 enviado para o Thingspeak

```

Fonte: Próprio Autor

Na Figura 44 encontrada nos anexos, é possível ver os dois sensores de irradiância lado a lado, evidenciando o que foi dito anteriormente que, caso necessário, é possível conectá-los simultaneamente. Porém a posição final do sensor de irradiância pode ser vista na seção dos anexos na Figura 45 que representa a irradiância incidente na inclinação que o módulo está instalado.

Além deles, é possível ver o sensor de temperatura direcionado para cima para ser possível avaliar a sensação térmica, ao lado dele temos o anemômetro. Abaixo se tem o sensor de umidade e temperatura ambiente, do esquerdo da placa do microcontrolador.

Após aproximadamente uma semana fazendo medições corretamente o piranômetro começou a apresentar algumas inconsistências nos dados, tratando de um problema em seus números, fez-se necessário a ida para a verificação do possível problema, já que se tratava de um problema de hardware, ao fazer-se presente na usina os colaboradores identificaram um possível erro de solda fria, sendo assim necessário a remoção da placa da usina para a remoção

do erro e aplicar os testes com intuito de colocá-la de novo em situação real.

Após a retirada da placa e do piranômetro de campo para testes foi verificado que o problema tratava de uma solda fria e foi necessário a troca do fusível após um surto elétrico.

Após verificar através da plataforma *online* do inversor *AuroraVision* os dados eram enviados a cada 15 minutos foi feita uma alteração no *firmware* do projeto para que os dados ficassem sincronizados com os dados do inversor, de modo que enviasse os valores coletados no mesmo momento em que o inversor envia para evitar divergências devido ao tempo, pois é sabido que de um minuto para o outro é possível que uma nuvem se prolongue sobre um módulo e assim afete a produção de toda a *string*, por isso é necessário o ajuste de forma que os dados coletados permaneçam o mais próximo possível.

Além disso, ao verificarmos os dados coletados pelo inversor com os que estavam sendo enviados pelo sensor era visível alguma discrepância em certos momentos, principalmente aqueles em que havia alguma interferência de nuvens, isso foi observado e resolvido após ser compreendido que os dados enviados pelo inversor são dados integralizados dentro daqueles 15 minutos, isto é, os dados coletados a cada instante são somados e divididos pelo número de intervalo, os valores enviados estavam sendo valores apenas daquele momento em que foi feita a medição, ou seja, apenas um recorte de todo aquele tempo, por isso foi feito um *upgrade* no código de modo que a cada minuto fosse coletado um dado e no final dos quinze minutos fosse feita a média daquele tempo para que minimizasse os erros referentes a esse problema do recorte, foi verificado uma proximidade bem maior em relação aos dados de corrente fornecidos pelo inversor, porém ainda com uma pequena diferença, já que há alguma imprecisão no sensor de corrente conectado à placa.

Por fim, para manter todo o projeto em seus moldes desejados foi-se necessária a utilização de mais cabo manga, no intuito de prolongar o sensor de irradiância e colocá-lo na mesma angulação do módulo para medições dos raios incididos que são captados para a geração de energia.

Porém, após o projeto ter sido finalizado em todas suas instâncias físicas, houve outro empecilho, mas agora referente a distribuidora de energia, após ir trocar o transformador houve um problema na geração da usina e passou mais de 60 dias sem geração, interrompendo a coleta de dados constante para que houvesse um desenvolvimento e análise de dados de uma forma fixa.

Foi possível coletar os demais dados, porém com a geração paralisada não há circulação

de corrente produzido pelos painéis e assim não há como analisar os valores de corrente nesse mês, sendo o dado da corrente o mais importante para analisar a geração não havia como correlacionar os demais dados com a produção de energia nesse período em que a concessionária não corrigiu tal erro.

## 4. RESULTADOS E DISCUSSÕES

Neste capítulo é apresentado o princípio de funcionamento do sistema proposto e a descrição da interface Web desenvolvida para a interação entre o usuário e o SAD. Finalmente, são mostrados os resultados obtidos experimentalmente com uso da arquitetura implementada

### 4.1 Desenvolvimento do algoritmo

Para o estudo dos dados coletados foi utilizado a linguagem de programação Python 3.6, além do uso da biblioteca de código aberto KERAS e scikit-learn que são excelentes para implementar redes neurais de bom desempenho.

A base de dados é composta por 23786 dados que são representados por coletas das variáveis a cada quinze minutos entre os dias 15-04-2021 até 03-01-2022, ou seja, 263 dias de dados analisados. Foram selecionadas apenas as colunas que seriam necessárias para o treinamento do modelo de previsão de corrente. As variáveis foram: Irradiância, Umidade, temperatura ambiente, temperatura dos painéis e velocidade do vento.

Para o treinamento da rede foi preciso tratar os dados para o modelo adequado de treinamento, logo foram feitos alguns ajustes:

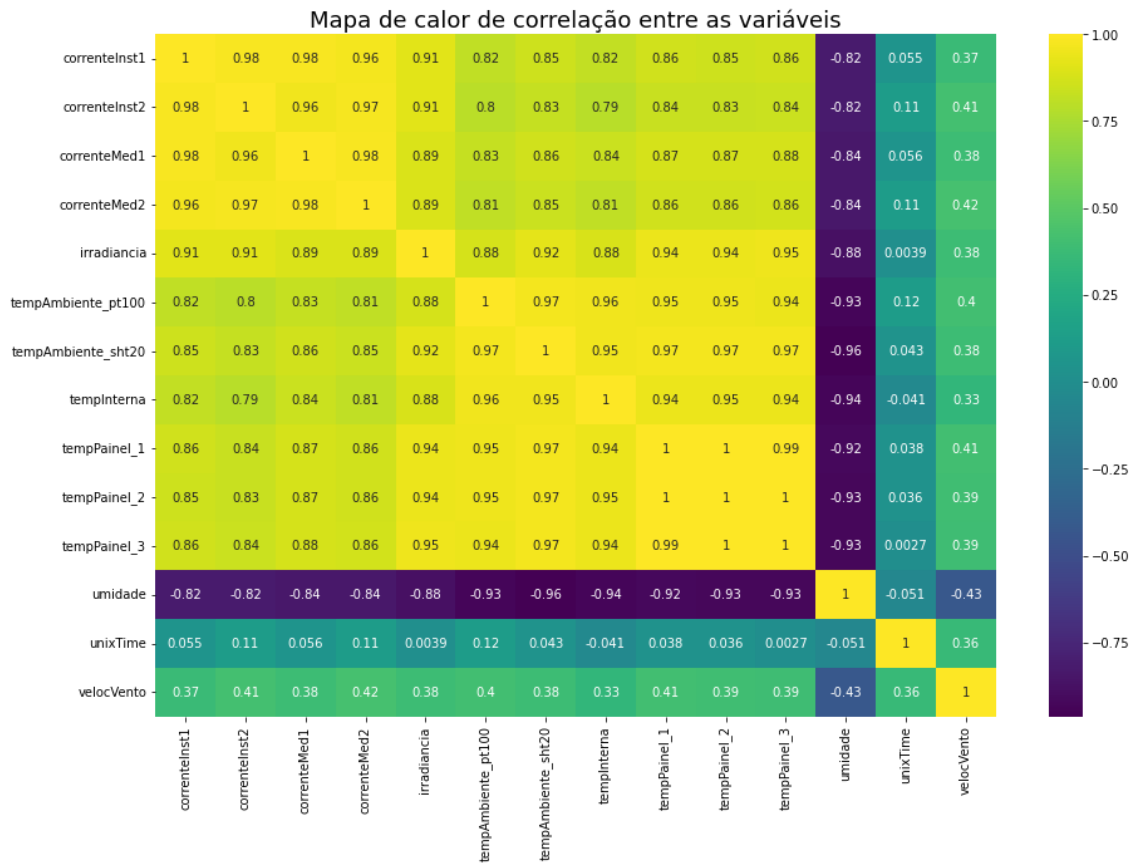
Conversão dos dados de .json para dados em .csv para facilitar o tratamento dos mesmos como se fossem uma planilha.

O dado coletado pelo RTC foi coletado por UnixTime para facilitar o armazenamento dos dados no FireBase, por isso, primeiramente era necessário passar o tempo que fora coletado em Unix Time para datas no formato de Ano-Mes-Dia-Hora-Minuto-Segundo.

Excluir os outliers de velocidade do vento. Sempre que havia uma desconexão o primeiro dado de velocidade do vento vinha distorcido da realidade como valores próximos de 1000 ou menor que 0. Então foi necessário excluir esses dados para não interferir no treino.

Após esse tratamento, foram selecionadas apenas as colunas que seriam necessárias para o treinamento do modelo de previsão de corrente através de uma análise de correlação (Figura 45) das variáveis e o entendimento de que haveria variáveis que representariam a mesma grandeza. As variáveis foram: Irradiância, Umidade, temperatura ambiente, temperatura dos painéis e velocidade do vento.

Figura 45 – Análise de correlação das variáveis coletadas



Fonte: Próprio Autor

Foram utilizados para representar a temperatura ambiente o valor coletado pelo PT100 que correspondia a um sensor mais acurado que o SHT20. Além disso a corrente que será prevista e usada para treino foi a corrente média da *String* 1, já que é onde os sensores de temperatura do módulo estão fixados. Para a variável de temperatura do módulo foi calculada a média dos 3 sensores instalados para representar a temperatura média da *string*. A Tab. 3 mostra os valores máximos e mínimos e médios de cada variável em toda a base de dados coletada.

Tabela 3 – Valores máximo e mínimo de todas

	Corrente Média(A)	Irradiância (W/m <sup>2</sup> )	Umidade (%)	Temp Ambiente (°C)	Temp Painel (°C)	Velocidade do Vento (m/s)
Mínimo	0	0	26,11	15,29	16,98	0
Média	2,05	248,55	73,92	26,13	31,16	0,79
Máximo	8,85	1358,94	104,42	37,19	62,56	2,65

Primeiro passo foi analisar as correlações das variáveis analisadas com a geração de corrente (Figura 46). Como é possível analisar, o maior impacto vem da Irradiância do momento, seguido da temperatura dos painéis, seguido pela umidade ambiente e temperatura ambiente. O que apresentou a pior correlação foi a velocidade do vento em relação a geração de corrente. Uma observação interessante a se analisar é a temperatura do painel impactar positivamente, já que todos os datasheets informam que é exatamente o contrário, porém essa análise dos fabricantes é dada com a manutenção da irradiância constante, nesse caso a irradiância é relacionada diretamente com a temperatura do painel como podemos ver pela Figura 2, a irradiância tem correlação de 0,94 com a temperatura do painel.

Para a umidade ambiente, podemos analisar que os valores de correlação negativa vêm pela influência das chuvas no aumento da umidade. Períodos chuvosos sempre são os mais prejudiciais para a geração de energia FV devido à presença de chuva representar tempos mais nublados e assim com menos irradiância incidindo sob os painéis.


Para o pré-processamento dos dados para o treinamento foi necessário normalizar todas as variáveis entre 0 e 1. Um motivo que se faz a normalização dos valores é aplicado pela descida do gradiente que converge muito mais rápido com valores normalizados, além disso, auxilia na função de perda.

“O melhor desempenho do sistema seria potencialmente atingido sob condições de maior irradiância solar, menor precipitação pluviométrica, menor temperatura, maior velocidade do vento e menor umidade relativa do ar.” (Silva et al, 2018,).

Nossa análise de correlação está de acordo com o estudo feito por Silva et al, 2018. Um ponto de ressalva que temos em relação ao estudo é que no nosso caso a temperatura está influenciando positivamente na geração de energia, mas no nosso caso é uma variável que seu aumento está relacionado diretamente ao aumento no nível da radiação solar.



Figura 46 – Análise de correlação das variáveis principais



Fonte: Próprio Autor

Após feita a análise das correlações treino foi iniciado o treinamento da rede neural para essa série temporal. A Figura 47 mostra a arquitetura de rede neural LSTM utilizada na pesquisa. A entrada da rede é composta por uma janela de tempo de 15 minutos onde cada valor são os valores das leituras dos sensores instalados em campo naquele momento. Todos esses valores são inseridos nas camadas do LSTM onde constituem a primeira camada da rede que é composta por 30 camadas. As saídas de cada célula são enviadas para a camada densamente conectada que gera como saída os valores de corrente referente ao próximo momento. Através desse método é possível estimar a corrente futura. Uma arquitetura similar a essa foi utilizada no trabalho de (Icaro et al, 2020).

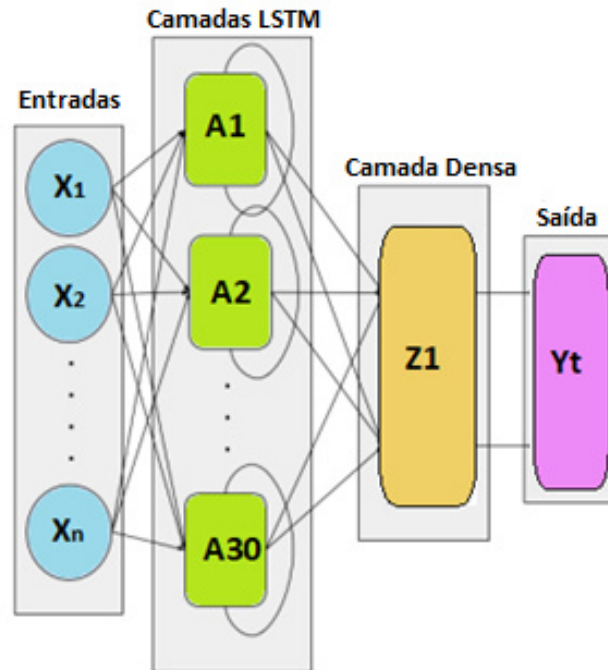
Dentre os parâmetros que mais influenciam no desempenho de uma rede neural está a escolha do otimizador, função que tem como objetivo diminuir o erro entre os resultados obtidos por uma rede em comparação com os resultados desejados. De modo geral, quanto menor o erro obtido por uma rede neural, maior a acurácia dos resultados e consequentemente melhor o desempenho da rede (Athyrson et al, 2020).

Para o treinamento foram utilizados o otimizador Adam e a função de perda erro quadrático médio, essa é uma escolha padrão na maioria dos casos em que se utiliza LSTM

(QING et al, 2018).

Para avaliar o modelo foi analisada a diferença entre o valor predito e o valor medido que deveria ser naquele momento, tanto pelo sensor quanto pelo inversor.

Figura 47 – Arquitetura da rede neural desenvolvida para o modelo em questão



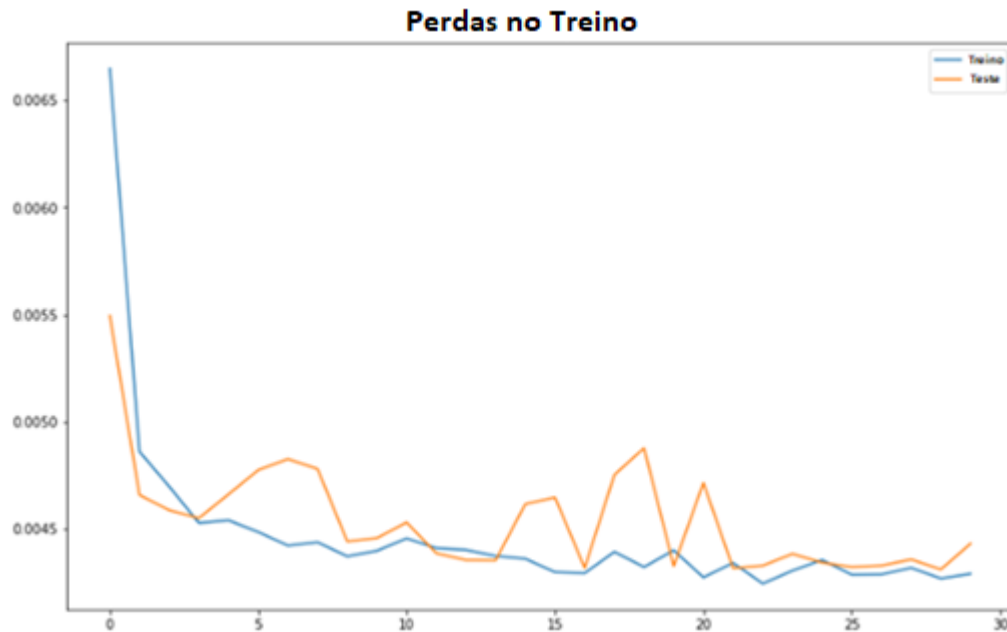
Fonte: Próprio Autor

Após o tratamento dos dados foram separados os dados entre dados de treino e dados de teste. Para a situação foi escolhido 1 mês para testes e o restante para treinar o modelo. Desta maneira, a data limiar que dividia o teste e o treino era 2021-12-03 às 00:00. Qualquer data antes disso fora utilizado para treino e posterior para teste, gerando assim, 2738 dados para testes e 21045 dados para treino.

## 4.2 Análise dos Resultados

Iniciando o treinamento da rede com esses dados e após diversos testes foi definido as épocas como 30 e o *dropout* como 0.2, ou seja, 20% dos piores nós seriam excluídos do treinamento para maior assertividade. O resultado final do treinamento foi representado pela figura 48.

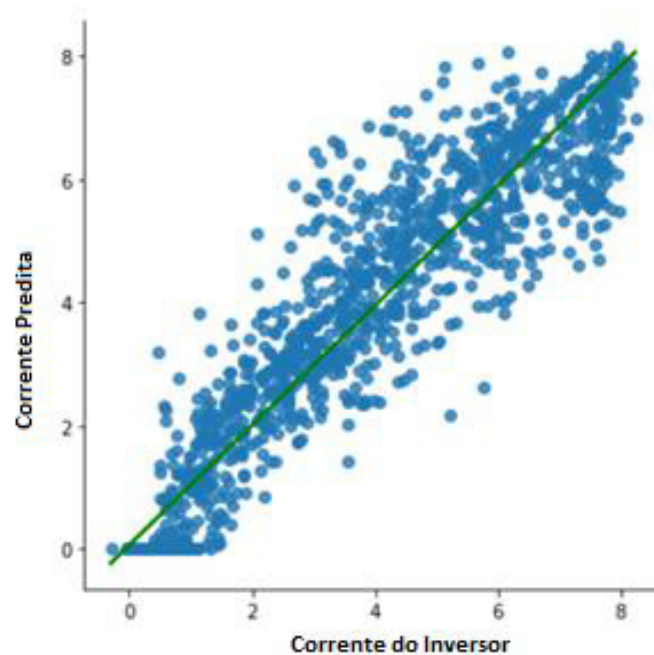
Figura 48 – Resultado final do treinamento analisando a perda nos dados de treino e teste.



Fonte: Próprio Autor

Além do treinamento do modelo com os dados do sensor também foram coletados os dados do inversor, ou seja, o valor de corrente enviado propriamente para a rede elétrica. Para entender o comportamento dos dados do inversor relacionado aos dados coletados pelo sensor foi analisado um gráfico de dispersão dos dados (Figura 49).

Figura 49 – Dispersão de dados entre os valores de corrente do sensor WCS1800 e do Inversor.



Fonte: Próprio Autor

Foram utilizadas duas métricas para avaliar a correlação e qualidade do modelo. O R2 Score apresenta-se como uma medida estatística de quão próximo os dados estão relacionados. Conhecido também como coeficiente de determinação. Em geral, o R2 Score determina quanto o modelo se ajusta aos dados. Para avaliar o erro do modelo foi utilizado RMSE (*Root Mean Square Error*) que é a medida que calcula “a raiz quadrática média” dos erros entre valores observados.

É possível avaliar que a maioria dos dados se encontram próximo a reta perfeita, apresentando os seguintes resultados de semelhança dos dados que representam uma proximidade correlação excelente dos dados, demonstrando uma boa acurácia do sensor nessa aplicação.


*R2 Score = 0,931;*

*RMSE = 0,671.*

Para analisar o erro de maneira mais precisa foram separados os dados em dados horários e analisado onde houve maior discrepância dos dados (Figura 50). Foi somado todos os valores horários de corrente do inversor que estava no modelo de teste, ou seja, depois do dia 03/12/2021 e comparado com os valores de corrente do mesmo período captado pelo sensor.

Pode-se analisar que as maiores diferenças acumuladas foram dadas por pelas horas (6, 14 e 15). Em valores mais centrais o erro ficava mais próximo de 0.

*Figura 50 – Dispersão dos dados de diferença entre os valores de corrente coletados pelo WCS1800 e pelo inversor*




Fonte: Próprio Autor

As diferenças entre esses valores nesses horários podem ser causadas pela tecnologia MPPT (*Maximum Power Point Tracking*) que é a capacidade do inversor de se adaptar a melhor curva de potência, algo que o sensor de corrente não consegue captar.

Para todo o período de teste, ou seja, os 28 dias a comparação foi a representada pela Figura 51. Além disso, foi analisado também o gráfico de dispersão para saber a qualidade dos dados gerados e podemos ver que o modelo apresenta uma boa qualidade.

Após executado o treinamento do modelo, foram visualizados os dados das três variáveis de corrente que temos (Variável predita, variável do sensor e variável do inversor) para analisar o modelo criado e os resultados foram representados pela figura 51. Como é possível ver, durante esses últimos 28 dias de teste houve uma queda na coleta dos dados devido à falta de conexão à rede wifi entre os dias 24 e 28.

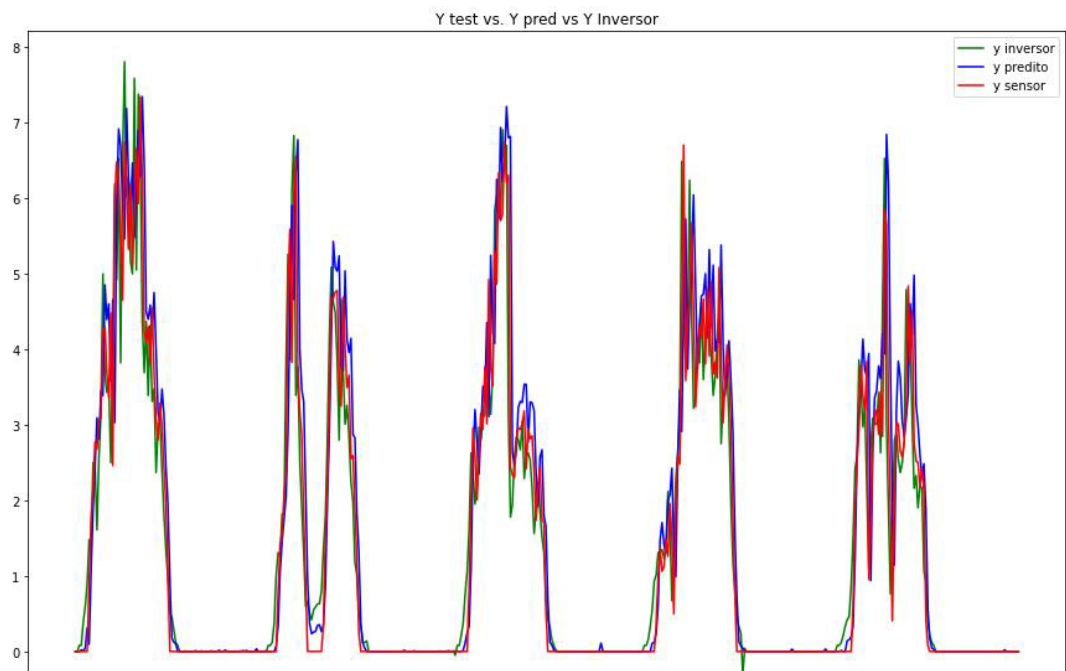
*Figura 51 – Comparação do modelo em todo o período de teste*



Fonte: Próprio Autor

Para melhor visualização, há a figura 52 que representa os últimos 5 dias do teste.

Figura 52 – Representação do modelo nos últimos 5 dias de teste.



Fonte: Próprio Autor

É possível avaliar que os valores de corrente do modelo correspondem de maneira satisfatória aos dados de corrente elétrica do sensor (WCS1800) e aos dados de corrente coletados pelo inversor. Porém em quedas bruscas os valores preditos não acompanham bem o modelo, enquanto a corrente do inversor alcança picos maiores devido a tecnologia do *MPPT*. Pode-se analisar também por essas visualizações a sensibilidade do sensor de corrente que não transita em valores muito pequenos, no início de cada dia vemos a subida gradual da corrente do inversor, enquanto no sensor permanece nula até atingir um valor mínimo que é captado por ele. Por essas particularidades é possível entender o gráfico de dispersão da Figura 6 que evidencia que as maiores diferenças estão nos horários de 6:00, 14:00 e 15:00.


Para analisar a qualidade do modelo visualizamos um dado de dispersão dos dados do valor predito e do valor medido propriamente conforme é possível ver na figura 53. Ressalta-se a sensibilidade no sensor ao analisarmos o gráfico de dispersão e observar a quantidade de pontos em que o eixo x permanece em zero enquanto o eixo y começa sua escalada.

As métricas de análise do modelo em relação aos dados do sensor foram de:

$R^2 \text{ Score} = 0,947;$

$RMSE = 0,613 \text{ A.}$

Figura 53 – Análise de dispersão dos dados preditos e medidos pelo WCS1800.




Fonte: Próprio Autor

Para analisar o erro do modelo foi utilizado uma visualização de diagrama de caixas ou *boxplot*. Durante os 28 dias de teste foi analisado o erro entre todos os dados e avaliado em qual intervalo a maior parte deles se enquadravam.

Conforme mostrado no *boxplot* da figura 54, a diferença entre o valor de corrente coletado pelo sensor e o valor predito temos que, para o sensor e o modelo temos que o terceiro quartil (Q3) é igual a 0.77A e a mediana encontra-se em 0.37A.


Figura 54 - Boxplot da diferença entre os valores de corrente coletados pelo sensor (WCS1800) e preditos.



Fonte: Próprio Autor

Conforme o *boxplot* da figura 55, é mostrada a diferença entre o valor de corrente coletado pelo inversor e o valor predito temos que o nosso Q3 é igual a 1.12, ou seja, 75% dos erros estão abaixo desse valor e a mediana está em aproximadamente 0.6A

Figura 55 – Boxplot da diferença entre os valores de corrente medidos pelo inversor e preditos.




Fonte: Próprio Autor



### 4.3 – Análise do resultado excluindo velocidade do vento

Após executado o treinamento incluindo todas as variáveis de entrada indicadas acima, fora analisado o impacto da velocidade do vento medida pelo sensor no desempenho do modelo devido a sua baixa correlação em relação a corrente conforme foi mostrada na figura 46. Devido a isso o treinamento de um modelo considerando apenas as variáveis de temperatura ambiente, temperatura dos painéis, umidade e irradiância fez-se necessária. Executado o treinamento e visualizado os gráficos para todos os dados de teste (Figura 56) foram analisadas as métricas. Importante salientar que houve uma queda na coleta dos dados devido à falta de conexão à rede wifi entre o período de 24 e 28 de dezembro de 2021.

Figura 56 - Análise do modelo sem a velocidade do vento em todo o período de teste.



Fonte: Próprio Autor

As métricas de análise nesse caso foram:

$$R2 \text{ Score} = 0,948$$

$$RMSE = 0,592 A$$

É possível avaliar que em relação ao R2 que representa o coeficiente de correlação permaneceu-se quase o mesmo, porém no RMSE houve uma diminuição de 3.5%, o que representa uma melhoria no modelo que poderia ser sentida também na análise dos *boxplots* dos erros em comparação com o modelo que inclui a velocidade do vento (Tabela 4), principalmente, na redução dos erros nos valores mais baixos, enquanto nos valores mais altos ela apresenta-se menos relevante.

*Tabela 4 – Comparação de erros entre os modelos com e sem velocidade do vento.*

	Modelo com Velocidade do vento	Modelo sem velocidade no vento	Impacto no desempenho (%)
Mínimo (A)	0	0	0
Primeiro Quartil (Q1) (A)	0,079	0,055	30
Mediana (A)	0,37	0,33	11
Terceiro Quartil (Q3) (A)	0,77	0,75	3
Máximo (A)	1,76	1,73	2

O impacto negativo no modelo ocasionado pela velocidade do vento dar-se pela imprecisão do sensor instalado, que trata-se de um sensor muito trivial e simples de pouca tolerância a erros, além disso, a instalação da estação meteorológica ter sido instalada a altura dos módulos cercada por vegetações e muros dificulta a coleta precisa dos dados de velocidade do vento.

## 5 - CONCLUSÃO

O presente TCC teve como objetivo elaborar a viabilidade de um projeto de telemetria que permitisse monitorar remotamente os dados de uma usina solar FV através de suas variáveis de geração e climáticas, assim foi possível entender o impacto dessas grandezas para a geração FV. Além disso, foi elaborado um modelo de previsão futura que permitisse a identificação de possíveis quedas de desempenho futuros. Para tal foi utilizada a Rede Neural Recorrente LSTM que segundo estudos é apresentada como a melhor rede neural para preditor de séries temporais de geração de energia elétrica. Foi desenvolvido um modelo que previsse a corrente de acordo com os dados climáticos do momento e obteve-se indicadores de erros aceitáveis com valores abaixo de 0.77 A em 75% dos dados analisados, o que possibilita a identificação de falhas. Ademais, foi identificado que nem todos os sensores tiveram impactos positivos no modelo como foi o caso da velocidade do vento que foi observado, por diferentes motivos, que impactava o modelo de maneira a aumentar seu erro.

O TCC residiu em um projeto completo, desde a concepção da ideia até a criação do modelo de inteligência artificial, possibilitou o acesso ao conhecimento de toda a instalação de um projeto físico e suas dificuldades na montagem. A importância desse trabalho reside na análise de aspectos positivos em relação a desempenho de usinas FV que podem gerar a partir do projeto executado e o impacto positivo causado por essas possibilidades encontra-se na praticidade que leva a cargos de técnicos de manutenção que pode atuar de maneira mais eficaz ao analisar os dados climáticos ao invés de analisar apenas corrente. Também foi comprovado que os valores coletados pelos sensores de correntes instalados em campo não serão completamente iguais aos valores de corrente que o inversor instalado envia para a rede, o inversor com a sua tecnologia de MPPT impossibilita isso além do sensor possuir certa sensibilidade de 66mV/A, que o impede de transitar em valores irrisórios.

Por fim, foram alcançados os objetivos preliminares de construir um projeto de telemetria que conseguisse captar e monitorar os dados em tempo real evidenciando a viabilidade técnica desse projeto para prever a geração de energia FV. Após a coleta dos dados também foi possível trata-los de modo a se obter um resultado satisfatório na previsão de corrente. Para o modelo incluindo como variável de entrada a velocidade do vento foi obtido um RMSE de 0,613A e 75% dos erros abaixo de 0,77A e para o modelo excluindo a velocidade do vento tivemos um RMSE de 0,592A e 75% dos erros abaixo de 0,75A o, além de índices de correlação próximos aos 95. Evidenciando o impacto negativo na inclusão da velocidade do vento para esse modelo, esclarecido anteriormente que por alguns motivos como relevo do local e da localização do sensor é posto em questionamento a importância de um sensor de velocidade

do vento para modelos em que a usina está instalada em locais murados e com vegetação abundante ao redor e assim apresentando velocidades do vento baixas que não são o bastante para impactar na geração de energia FV.

Para projetos futuros o trabalho possibilita:

- Impacto econômico para os interessados de um projeto de telemetria em uma usina FV, podendo extrapolar para outras usinas além da explorada na dissertação;
- Análise do impacto das variáveis climáticas na produção de energia em um clima tropical similar ao do local da usina;
- Análise de viabilidade de tornar-se um projeto de telemetria um produto comercializado entre empresas do ramo de energia solar;
- Análise de desempenho da usina instalada em condições climáticas como as da região.
- Melhorias na instalação física do projeto e seu impacto no monitoramento das variáveis
- Análise para utilização de Telemetria para recurso de recontabilização do SMF (Sistema de Medição e Faturamento)

## REFERÊNCIAS

A. Gensler, J. Henze, B. Sick and N. Raabe, "**Deep Learning for solar power forecasting — An approach using AutoEncoder and LSTM Neural Networks,**" *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2016, pp. 002858-002865, doi: 10.1109/SMC.2016.7844673.

Cantor, Guillermo Andrés Rodríguez. **INFLUÊNCIA DOS FATORES CLIMÁTICOS NO DESEMPENHO DE MÓDULOS FOTOVOLTAICOS EM REGIÕES DE CLIMA TROPICAL.** 2017. 177 f. Dissertação (Mestrado) - Curso de Pós-graduação em Energias Renováveis, Centro de Energias Alternativas e Renováveis, Universidade Federal da Paraíba, João Pessoa, 2017.

CASTRO, Fernando Luiz de. **Análise de um sistema fotovoltaico integrado à iluminação pública eficiente.** 2018. 83 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal de Uberlândia, Uberlândia, 2018.

Datasheet Canadian Solar CS6U-P. Acesso em mar/22. Disponível em: <https://download.aldo.com.br/pdfprodutos/Produto34226IdArquivo4451.pdf>

EPE [Empresa de Pesquisa Energética] **Balanco Energético Nacional (BEN) 2021:** Ano base 2021, 2022. Disponível em < <https://ben.epe.gov.br> >. Acesso em mar/2022.

Hochreiter, Sepp & Schmidhuber, Jürgen. (1997). **Long Short-term Memory. Neural computation.** 9. 1735-80. 10.1162/neco.1997.9.8.1735.

Grus, Joel. **Data Science do Zero.** Alta Books, 2016

IEA (2020), Energy technology perspectives. 2020. Disponível em < <https://www.iea.org/topics/energy-technology-perspectives>>. Acesso em mar/2022.

REINALDO, Pierre Moreno. **Análise Do Impacto Da Geração Distribuída Fotovoltaica Na Rede De Baixa Tensão Da Celesc**. 2020. Instituto Federal de Santa Catarina, 2020. Disponível em: <https://sobraep.org.br/site/uploads/2020/09/rvol25no03-12-0013-316-325.pdf>

**REN (2021), 2022 Renewables Global Futures Report**. Disponível em <  
<https://www.ren21.net/2022-renewables-global-futures-report/>>. Acesso em mar/2022

PANJWANI. M., NAREJO. G., **Effect of Humidity on the Efficiency of Solar Cell (photovoltaic)**. Department of Electronic Engineering, NEDUET, International Journal of Engineering Research and General Science Volume 2, Issue 4, June-July, Pakistan. 2014.

Pelland, Sophie & Remund, Jan & Kleissl, Jan & Oozeki, Takashi & De Brabandere, Karel. (2013). **Photovoltaic and Solar Forecasting: State of the Art**.

PEREIRA, E. B., et al. **Atlas Brasileiro de Energia Solar**, São José dos Campos: ed. INPE, 2006.

PEREIRA, Rodrigo Pereira. **Análise de viabilidade de uma planta híbrida, solar fotovoltaica e eólica: estudo de caso para Aracati-CE**. 2018. 84 f. Monografia (Graduação em Engenharia Elétrica) - Centro de Tecnologia, Universidade Federal do Ceará, 2018.

E. Skoplaki, J.A. Palyvos. **On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations**  
Sol. Energy., 83 (5) (2009), pp. 614-624,.

TAMIZHMANI, G. Et al. **Photovoltaic module thermal/wind performance: Long - Term Monitoring and Model Development For Energy Rating**. Arizona State University East, Photovoltaic Testing Laboratory, NCPV and Solar Program Review Meeting. Meza, Arizona. 2003.

VILLALVA, M.; GAZOLI, J. **Energia solar fotovoltaica: conceitos e aplicações**. 1. ed. São Paulo: Érica, 2012.

VILAR, Emerson. 2020. **ANÁLISE de Desempenho de Método Baseado em Rede LSTM para Classificação de Falhas em um Processo de Controle de Nível**. Dissertação (Engenharia Elétrica) - Mestrado, [S. l.], 2020.

UNIVERSIDADE FEDERAL DO CEARÁ. Biblioteca Universitária. **Guia de normalização de trabalhos acadêmicos da Universidade Federal do Ceará**. Fortaleza: Biblioteca Universitária, 2013. Disponível em: <https://biblioteca.ufc.br/wp-content/uploads/2019/10/guia-de-citacao-06.10.2019.pdf>. Acesso em: 9 jun. 2021.


Qing X., Niu Y. **Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM**. Energy, 148 (2018), pp. 461-468

Yagli, Gokhan Mert & Yang, Dazhi & Srinivasan, Dipti, 2019. **"Automatic hourly solar forecasting using machine learning models,"** Renewable and Sustainable Energy Reviews, Elsevier, vol. 105(C), pages 487-498.

Galvani e Luchari, 2004. **“CRITÉRIOS PARA CLASSIFICAÇÃO DE ANOS COM REGIME PLUVIOMÉTRICO NORMAL, SECO E ÚMIDO”**, Anais do X Encontro de Geógrafos da América Latina

## ANEXOS

*Figura 18 – Conceito da Lista Encadeada Circular*



Fonte: Próprio Autor

*Figura 25 - Local de Fixação do sensor de corrente e fixação do cabo*



Fonte: Próprio Autor



*Figura 26 – Ponto de Conexão Wi-Fi da Usina*



Fonte: Próprio Autor

*Figura 27 – Ponto de Conexão 220V e Local de Fixação do módulo de Alimentação*



Fonte: Próprio Autor

*Figura 28 – Registro das Strings utilizadas para as medições*



Fonte: Próprio Autor

*Figura 44 – Posição do sensor de Irradiância*



Fonte: Próprio Autor

