



UFC

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

LAYSON KILBER GARCIA GOMES

**DIMENSIONAMENTO E OTIMIZAÇÃO DE KITS DE GERAÇÃO FOTOVOLTAICA
VIA IA/CHATBOT**

FORTALEZA, 10 de setembro de 2024

LAYSON KILBER GARCIA GOMES

**DIMENSIONAMENTO E OTIMIZAÇÃO DE KITS DE GERAÇÃO FOTOVOLTAICA
VIA IA/CHATBOT**

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.

Orientador(a): Prof. Dr. Dalton de Araújo Honório

Coorientador(a): Eng. Me. Paulo Honório Filho

FORTALEZA, 10 de setembro de 2024

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

G615d Gomes, Layson Kilber Garcia.
Dimensionamento e Otimização de Kits de Geração Fotovoltaica Via IA/ChatBot / Layson Kilber Garcia
Gomes. – 2024.
56 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia,
Curso de Engenharia Elétrica, Fortaleza, 2024.

Orientação: Prof. Dr. Dalton de Araújo Honório.
Coorientação: Prof. Me. Paulo Honório Filho.

1. Energia Solar. 2. Aprendizado de máquina. 3. Modelos de Linguagem Natural. 4. Dimensionamento
de Equipamentos. I. Título.

CDD 621.3

LAYSON KILBER GARCIA GOMES

**DIMENSIONAMENTO E OTIMIZAÇÃO DE KITS DE GERAÇÃO FOTOVOLTAICA
VIA IA/CHATBOT**

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.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Dalton de Araújo Honório (Orientador)
Universidade Federal do Ceará (UFC)

Eng. Me. Paulo Honório Filho (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Ronny Glauber de Almeida Cacao
Universidade Federal do Ceará (UFC)

B. Sc. Levi Almeida da Silva
Universidade Estadual do Ceará (UECE)

Dedico este trabalho, primeiramente, à minha família, cujo apoio incondicional sempre me guiou, e a todos aqueles que contribuíram nesta jornada.

AGRADECIMENTOS

Agradeço à minha mãe, Joana Gomes, pelo apoio inabalável e pela sabedoria com que me guiou e ainda me guia em cada passo da minha jornada, mostrando-me o caminho que me formou, tanto como pessoa quanto como profissional.

Ao meu pai, Francisco Gomes, que é um exemplo de integridade e inspiração. Através de seu incentivo, pude viver as experiências e desenvolver os conhecimentos que me trouxeram ao lugar onde estou hoje, pois ele me ensinou que o conhecimento tem o poder de transformar nossa visão de mundo.

À minha irmã, Laysa Kimberly, por seu apoio constante e por estar ao meu lado em cada etapa desta caminhada. Sua presença foi essencial para o meu crescimento.

Aos meus colegas de faculdade, com quem compartilhei experiências, aprendizados e lembranças. Mais do que colegas, eles se tornaram amigos preciosos, cuja amizade valorizo profundamente.

Por fim, ao meu professor orientador, Dalton Honório, e ao coorientador, Paulo Honório, pelo apoio e pela orientação que possibilitaram a realização deste trabalho.

RESUMO

Este trabalho tem como objetivo integrar duas tecnologias emergentes no atual contexto social e econômico: a energia solar, que desempenha um papel crucial na transição para uma economia de baixo carbono, e a Inteligência Artificial (IA), que está transformando diversos setores econômicos. O projeto propõe o desenvolvimento de uma ferramenta ChatBot capaz de realizar o dimensionamento de sistemas fotovoltaicos com base nos dados fornecidos pelo usuário, irradiância solar local, componentes fotovoltaicos e tarifas energéticas. Além disso, o ChatBot responderá de maneira natural a questões relacionadas à energia solar, utilizando a integração e ajuste da interface da OpenAI e um modelo classificatório pré-treinado com a arquitetura BERT (*Bidirectional Encoder Representations from Transformers*). Essa integração visa não apenas otimizar financeiramente o processo de dimensionamento, mas também disseminar conhecimento técnico sobre o tema, promovendo uma interação dinâmica e informativa com o usuário.

Palavras-chave: Inteligência Artificial, Engenharia Elétrica, Aprendizado de Máquina, Projeto Fotovoltaico, Dimensionamento de Equipamentos, Modelo de Linguagem de Larga Escala.

ABSTRACT

This work aims to integrate two emerging technologies in the current social and economic context: solar energy, which plays a crucial role in the transition to a low-carbon economy, and Artificial Intelligence (AI), which is transforming various economic sectors. The project proposes the development of a ChatBot tool capable of sizing photovoltaic systems based on user-provided data, local solar irradiance, photovoltaic components, and energy tariffs. Additionally, the ChatBot will respond naturally to questions related to solar energy by utilizing the integration and fine-tuning of OpenAI's interface and a pre-trained classification model with the BERT (Bidirectional Encoder Representations from Transformers) architecture. This integration seeks not only to financially optimize the sizing process but also to disseminate technical knowledge on the subject, promoting a dynamic and informative interaction with the user.

Keywords: Artificial Intelligence, Electrical Engineering, Machine Learning, Photovoltaic Project, Equipment Sizing, Large Language Model.

LISTA DE FIGURAS

Figura 1	– Exemplificação do Modelo Proposto (Autor)	19
Figura 2	– Componentes da Irradiação Solar (INPE, 2017)	20
Figura 3	– Representação Célula Fotovoltaica. (CRESESB, 2024)	22
Figura 4	– Modelo MLP (Multi-Layer Perceptron). (PECULIAR CODING ENDEAVOURS, 2019)	26
Figura 5	– Modelo CNN (Convolutional Neural Network) - Camada Convolutacional. (PECULIAR CODING ENDEAVOURS, 2019)	27
Figura 6	– Modelo CNN (Convolutional Neural Network) - Camada Pooling. (Autor)	28
Figura 7	– Mecanismo de Auto-Atenção. (BARATTO, 2022)	28
Figura 8	– Evolução da Capacidade Elétrica de Fontes Renováveis. (International Energy Agency (IEA), 2024)	31
Figura 9	– Modelo Proposto. (Autor)	33
Figura 10	– Resultado do Treinamento: 10 épocas, 32 labels positivas, 24 negativas (Autor)	35
Figura 11	– Resultado do Treinamento: 5 épocas, 32 labels positivas, 24 negativas (Autor)	36
Figura 12	– Resultado do Treinamento: 10 épocas, 44 labels positivas, 42 negativas (Autor)	36
Figura 13	– Resultado do Treinamento: 5 épocas, 44 labels positivas, 42 negativas (Autor)	37
Figura 14	– Fluxograma do Algoritmo de Dimensionamento (Autor)	46
Figura 15	– Interface do ChatBot - Início. (Autor)	47
Figura 16	– Interface do ChatBot - Conversa. (Autor)	48
Figura 17	– Interface do ChatBot - Dimensionamento. (Autor)	48
Figura 18	– Interface do ChatBot - Resposta de Dimensionamento. (Autor)	49

LISTA DE TABELAS

Tabela 1	– Técnicas de IA e suas aplicações em energias renováveis. (RANE; CHOUDHARY SAURABH P., 2024)	32
Tabela 2	– Métricas de Treinamento (Autor)	38
Tabela 3	– Fatores de Redução em Sistemas Fotovoltaicos (COURSES, 2020)	42

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
LLM	Large Language Model (Modelo de Linguagem de Grande Escala)
NLP	Natural Language Processing (Processamento de Linguagem Natural)
DL	Deep Learning (Aprendizado Profundo)
ANN	Artificial Neural Network (Redes Neurais Artificiais)
MLP	Multi-Layer Perceptron (Perceptron Multi-Camadas)
CNN	Convolutional Neural Network (Rede Neural Convolucional)
IA	Inteligência Artificial
GPT	Generative Pre-trained Transformer (Transformador Pré-treinado Generativo)
BERT	Bidirectional Encoder Representations from Transformers (Representações de Codificadores Bidirecionais de Transformadores)
CA	Corrente Alternada
CC	Corrente Contínua
PWM	Pulse Width Modulation (Modulação por Largura de Pulso)
STC	Standard Test Conditions (Condições de Teste Padrões)
API	Application Programming Interface (Interface de Programação de Aplicações)

LISTA DE SÍMBOLOS

<i>%</i>	Porcentagem
<i>R\$</i>	Real
<i>kW</i>	Quilowatts
<i>kWh</i>	Quilowatts-Hora
<i>Wh</i>	Watts-Hora
<i>MW</i>	Megawatts
<i>kWp</i>	Quilowatts-Pico
<i>C</i>	Celcius
<i>A</i>	Ampér
<i>V</i>	Volts
<i>W</i>	Watts

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Objetivos	19
2	FUNDAMENTOS E DEFINIÇÕES	20
2.1	Irradiação e Irradiância Solar	20
2.2	Células Fotovoltaicas	21
2.2.1	Princípio da Conversão Fotovoltaica	21
2.2.2	Junção pn e Efeito Fotovoltaico	21
2.3	Inversores Fotovoltaicos	22
2.3.1	Entrada de Corrente Contínua (CC)	22
2.3.2	Conversão Inicial PWM - <i>Pulse Width Modulation</i> (Modulação de Largura de Pulso)	23
2.3.3	Conversão de CC para CA	23
2.3.4	Filtragem da Corrente Alternada	23
2.3.5	Proteções e Monitoramento	23
2.3.6	Saída de Corrente Alternada (CA)	23
2.3.7	Tipos de Inversores Fotovoltaicos	24
2.4	Inteligência Artificial e Modelos LLM	24
2.4.1	Modelos de Linguagem de Grande Escala (LLM)	24
2.4.1.1	<i>Arquitetura e Funcionamento dos LLMs</i>	25
2.4.1.2	<i>Aplicações dos LLMs</i>	25
2.4.1.3	<i>Redes Neurais (ANN - Artificial Neural Network)</i>	25
2.4.1.4	<i>Deep Learning</i>	26
2.5	Classificação de Intenções de Texto com BERT via Treinamento Supervisionado	28
2.5.0.1	<i>Transformer</i>	29
2.5.0.2	<i>Tensores</i>	29
2.5.0.3	<i>Época (Epoch)</i>	29
2.5.0.4	<i>Tokenização e Embedding</i>	30
2.5.0.5	<i>Taxa de Aprendizado (Learning Rate) e Tamanho de Lote (Batch Size)</i>	30
2.5.1	Integração do <i>Machine Learning</i> com Energia Solar	31
3	METODOLOGIA	33
3.0.1	Solução Proposta	33
3.1	Configuração do Modelo Classificador e Treinamento	34
3.2	Integração com a API da OpenAI	38
3.3	Algoritmo de Dimensionamento	39
3.3.1	Carregamento das Bases	39
3.3.2	Cálculo do Consumo Energético Mensal	40
3.3.2.1	<i>Razão para Subtrair a Taxa Mínima</i>	40

3.3.3	Módulos Fotovoltaicos	41
3.3.3.1	<i>Energia Gerada</i>	41
3.3.3.2	<i>Tempo de Exposição</i>	41
3.3.3.3	<i>Fator de Redução (Derating)</i>	42
3.3.4	Potência Instalada e Máxima Potência do Módulo	43
3.3.5	Inversores de Potência	44
3.3.5.1	<i>Cálculos para Conexão em 1 String</i>	44
3.3.5.2	<i>Cálculos para Conexão em 2 Strings</i>	44
3.3.5.3	<i>Análise Comparativa</i>	45
3.4	<i>Payback</i>	45
4	RESULTADOS	47
5	CONCLUSÃO	50
6	TRABALHOS FUTUROS	51
	REFERÊNCIAS	52
	APÊNDICE A – Script de Treinamento de Modelo BERT	54
	APÊNDICE B – Algoritmo de Dimensionamento da Planta Fotovoltaica	55
	APÊNDICE C – Bases de Dados Utilizadas	56

1 INTRODUÇÃO

Nos últimos anos, o mundo testemunhou avanços extraordinários em diversas áreas, impulsionados pela constante evolução da tecnologia. Em particular, dois campos emergiram como pilares fundamentais para moldar o futuro da humanidade: a inteligência artificial (IA) e as energias renováveis. Ambos são catalisadores essenciais para enfrentar os complexos desafios do século XXI, desde a mitigação das mudanças climáticas até a melhoria da eficiência em diversos setores da sociedade.

A inteligência artificial, marcada pela capacidade das máquinas de aprender, raciocinar e tomar decisões, tem se mostrado uma ferramenta poderosa em inúmeras aplicações. Desde a automação de processos industriais até a personalização de serviços em larga escala, a IA está transformando radicalmente a maneira como interagimos com o mundo ao nosso redor. Através dos modelos de Linguagem de Grande Escala (LLM), vimos uma democratização significativa das IA, permitindo que muitas pessoas utilizem essas ferramentas para os mais diversos propósitos. Além disso, a crescente conscientização sobre o potencial da IA tem levado um número crescente de países e empresas a investir recursos substanciais no desenvolvimento e implementação dessa tecnologia (CARVALHO, 2021).

Enquanto a IA revoluciona a forma como lidamos com dados, desenvolvimento e comunicação, as energias renováveis representam uma abordagem crucial para a sustentabilidade ambiental. O aproveitamento de recursos naturais, como a luz solar, o vento e a água, para gerar energia limpa e renovável é um passo fundamental na transição para uma economia de baixo carbono. Segundo (RANE; CHOUDHARY SAURABH P., 2024), com as mudanças climáticas e a degradação ambiental representando desafios urgentes para a comunidade global, a importância de soluções energéticas renováveis e sustentáveis tornou-se ainda mais crucial.

A integração dessas duas tecnologias oferece um potencial significativo para avanços em diversos setores. Modelos de previsão baseados em inteligência artificial geralmente apresentam resultados mais notáveis em comparação com técnicas físicas e métodos estatísticos devido às suas habilidades potenciais para mineração de dados e extração de características. Por exemplo, a precisão das previsões em fontes de energia renovável é crucial para o planejamento, gestão e operações do sistema de energia, portanto, técnicas de *Machine Learning* (ML) como o *Deep Learning* (DL) têm sido usadas para detectar os padrões não lineares inerentes e as estruturas invariantes de alto nível nos dados (AJIBADE et al., 2023).

1.1 Objetivos

O objetivo deste trabalho é apresentar uma proposta de interface de interação humano-computador focada em energia solar, com três principais pilares de funcionalidade.

O primeiro é a capacidade de receber informações características do usuário e, associando-as com dados de irradiância solar local, tarifas energéticas e especificações técnicas de inversores e células fotovoltaicas, fornecer um dimensionamento fotovoltaico que visa o menor *payback* para as condições apresentadas.

O segundo pilar é a interação com o usuário: por meio da integração com a Interface de Programação de Aplicações (API, do inglês *Application Programming Interface*) da OpenAI (ChatGPT), a ferramenta deve oferecer respostas sobre tópicos gerais relacionados à energia solar.

Por fim, o terceiro pilar envolve a capacidade do modelo de tratar e analisar os dados fornecidos pelo usuário, classificando a intenção de realizar o dimensionamento com base em um modelo classificatório e diferenciando os assuntos relacionados ao tema do projeto de outros temas não pertinentes.



Figura 1 – Exemplificação do Modelo Proposto (Autor)

2 FUNDAMENTOS E DEFINIÇÕES

Neste capítulo, serão abordadas as definições e conceitos que envolvem a energia solar e sua produção no mercado brasileiro, bem como as características dos principais equipamentos utilizados. Além disso, será apresentada uma explicação breve sobre os modelos de Linguagem de Grande Escala, destacando suas funcionalidades e aplicabilidades.

2.1 Irradiação e Irradiância Solar

Irradiação e irradiância são termos semelhantes, porém representam espectros diferentes da energia emitida pelo sol. Irradiância representa o fluxo de energia radiante instantâneo que incide sobre uma superfície, real ou imaginária, por unidade de área. Sua unidade de medida é (W/m^2). (ENERGES, 2019)

Já a Irradiação é a quantidade de energia radiante que incide em uma superfície durante um certo intervalo de tempo, por unidade de área desta. Ou melhor, é a irradiância num intervalo de tempo. Sua unidade de medida é dada em (Wh/m^2). A irradiação diária pode ser em ($Wh/m^2.dia$), por exemplo. (ENERGES, 2019)

Entender essa diferença é essencial para dimensionamento de sistemas, como por exemplo energia solar fotovoltaica on grid, off-grid e sistemas de aquecimento solar, que a irradiação interfere diretamente nos cálculos.

A irradiância solar (Wh/m^2) que incide em uma superfície é composta por suas componentes direta e difusa. A irradiância solar direta apresenta direção de incidência na linha imaginária entre a superfície e o Sol e representa a parcela que não sofreu os processos radiativos de absorção e espalhamento que ocorrem na atmosfera. A componente difusa engloba a radiação proveniente de todas as demais direções que são decorrentes dos processos de espalhamento pelos gases e particulados presentes na atmosfera. (INPE, 2017)




Figura 2 – Componentes da Irradiação Solar (INPE, 2017)

2.2 Células Fotovoltaicas

As células fotovoltaicas são dispositivos que convertem diretamente a energia da irradiação solar em eletricidade através do efeito fotovoltaico. Esse efeito ocorre em materiais semicondutores, que possuem uma estrutura de bandas de energia, separadas por uma banda proibida (gap de energia). Existem na natureza diversos materiais semicondutores, que são caracterizados por possuírem uma banda de valência preenchida por elétrons e uma banda de condução vazia a baixas temperaturas. (FADIGAS, 2017)

Segundo (FADIGAS, 2017), o silício é o semicondutor mais amplamente utilizado para a fabricação de células fotovoltaicas. Isso se deve a várias de suas propriedades que o tornam particularmente adequado para esse processo. Primeiramente, o silício é o segundo elemento mais abundante na crosta terrestre, o que faz dele uma opção economicamente viável e amplamente disponível. Além disso, suas propriedades eletrônicas são favoráveis para a conversão de energia solar, apresentando um gap de energia ideal para garantir uma boa eficiência na transformação de luz solar em eletricidade.

2.2.1 Princípio da Conversão Fotovoltaica

O silício possui quatro elétrons de valência que se ligam aos átomos vizinhos, formando uma rede cristalina. Ao adicionar átomos com cinco elétrons de valência, como por exemplo o fósforo, haverá um elétron em excesso que não poderá se associar a outro átomo. Esse elétron, estando fracamente ligado ao seu átomo de origem, pode ser facilmente excitado para a banda de condução com uma pequena quantidade de energia térmica. O fósforo é considerado um dopante doador de elétrons e denomina-se dopante tipo n.

De forma análoga, a partir da adição de átomos com somente três elétrons de valência, haverá um déficit de um elétron em relação aos átomos de silício da rede. Esta falta de elétron é chamada de lacuna e facilita para que, com pouca energia térmica, um elétron vizinho preencha essa posição, fazendo com que a lacuna se desloque. Um exemplo de dopante que causa esse resultado é o boro, chamado de dopante tipo p.

2.2.2 Junção pn e Efeito Fotovoltaico

Se, partindo de um silício puro, forem introduzidos átomos de boro em uma metade e átomos de fósforo na outra, será formada a chamada junção pn. Na junção, os elétrons livres do lado n se difundem para o lado p, onde encontram lacunas e se recombina. Isso resulta em um acúmulo de cargas negativas no lado p e cargas positivas no lado n. Essas cargas aprisionadas geram um campo elétrico interno que impede a difusão adicional de elétrons do lado n para o lado p, atingindo um estado de equilíbrio.

Quando a junção pn é exposta a fótons com energia maior que o gap do silício, ocorre a geração de pares elétron-lacuna como explicitado na Figura 3. Se isso acontecer na região da junção, onde o campo elétrico é significativo, esses pares são separados: os elétrons são puxados para o lado n e as lacunas para o lado p. Esse movimento de cargas gera uma corrente através da junção, criando uma diferença de potencial conhecida como Efeito Fotovoltaico (GUERRA et al., 2018).




Figura 3 – Representação Célula Fotovoltaica. (CRESESB, 2024)

2.3 Inversores Fotovoltaicos

Um inversor fotovoltaico é um componente essencial em um sistema de energia solar. Ele desempenha a função crucial de converter a corrente contínua (CC) gerada pelos painéis solares em corrente alternada (CA), que é a forma de energia usada pela maioria dos dispositivos elétricos e, quando em condições aceitáveis, pode ser injetada na rede elétrica de distribuição (XIAO, 2017).

2.3.1 Entrada de Corrente Contínua (CC)

O processo começa nos painéis solares, que captam a luz solar e a convertem em eletricidade na forma de corrente contínua. No entanto, essa corrente contínua não é constante; sua produção varia de acordo com a intensidade da luz solar, o ângulo de incidência, a temperatura e outras condições ambientais. Essas flutuações na tensão e corrente geradas pelos painéis solares criam a necessidade de uma conversão para garantir o uso adequado dessa energia.

2.3.2 Conversão Inicial PWM - *Pulse Width Modulation* (Modulação de Largura de Pulso)

Para lidar com a variabilidade da corrente contínua, o inversor utiliza a técnica de modulação de largura de pulso (PWM). Essa técnica divide a corrente contínua em uma série de pulsos rápidos, cuja largura pode ser ajustada para controlar a quantidade média de energia transferida. Ao ajustar a largura dos pulsos, o inversor garante que a energia produzida seja otimizada, mesmo com as variações nas condições de entrada.

2.3.3 Conversão de CC para CA

Após a modulação de largura de pulso, a corrente contínua é transformada em corrente alternada. Isso é feito através de transistores de potência, que ligam e desligam rapidamente para imitar uma forma de onda senoidal, alternando de positiva para negativa. Essa conversão é necessária porque a corrente alternada é o padrão usado na maioria dos sistemas elétricos e na rede de distribuição de energia.

2.3.4 Filtragem da Corrente Alternada

No entanto, a corrente alternada gerada inicialmente pode conter irregularidades, devido ao processo de conversão. Para garantir que a eletricidade seja de alta qualidade e adequada para uso em dispositivos elétricos, o inversor passa a corrente por um filtro, suavizando a forma da onda e assegurando sua estabilidade.

2.3.5 Proteções e Monitoramento

Além de converter e filtrar a energia, os inversores modernos oferecem diversas proteções, como contra sobrecarga, curto-circuito e sobretemperatura, garantindo a segurança do sistema. Eles também incluem sistemas de monitoramento que permitem acompanhar a eficiência do inversor e identificar possíveis problemas, facilitando a manutenção preventiva e corretiva.

2.3.6 Saída de Corrente Alternada (CA)

Finalmente, a corrente alternada gerada pelo inversor está pronta para ser utilizada. Essa energia pode ser usada diretamente por aparelhos elétricos, armazenada em baterias em sistemas que possuem armazenamento, ou ser alimentada na rede elétrica, contribuindo para a distribuição de energia renovável.

2.3.7 Tipos de Inversores Fotovoltaicos

O tipo de inversor utilizado tem um impacto importante dentro do processo de dimensionamento. De acordo com (BOYD, 2024), os inversores fotovoltaicos podem ser classificados em diferentes tipos, de acordo com suas características e aplicações. Um dos tipos mais comuns são os inversores de cadeia, também conhecidos como *string inverters*, que conectam vários painéis solares em série. Esse tipo de inversor é amplamente utilizado em instalações residenciais e comerciais de médio porte, sendo eficiente para sistemas onde a uniformidade de produção entre os painéis solares é mantida.

Outro tipo de inversor é o microinversor, que é instalado diretamente em cada painel solar. Ao contrário dos inversores de cadeia, os microinversores otimizam a produção de energia de cada painel de forma individual, permitindo um melhor desempenho em situações onde há sombreamento parcial ou diferenças de orientação entre os painéis. Eles são ideais para maximizar a eficiência em sistemas menores ou em locais com condições variáveis.

Por fim, os inversores centrais são projetados para grandes instalações solares, como usinas de energia solar. Esse tipo de inversor é responsável por converter a energia gerada por várias cadeias de painéis solares ao mesmo tempo, sendo altamente eficiente para projetos de grande escala, onde a centralização do processo de conversão é vantajosa.

2.4 Inteligência Artificial e Modelos LLM

A inteligência artificial (IA) é um campo da ciência da computação focado na criação de sistemas capazes de realizar tarefas que, normalmente, exigiriam inteligência humana. Isso inclui atividades como aprendizado, raciocínio, reconhecimento de padrões, interpretação de linguagem natural e tomada de decisões. Nos últimos anos, a IA tem experimentado avanços significativos, impulsionados por melhorias em algoritmos, poder computacional e disponibilidade de grandes volumes de dados (NAVEED et al., 2024).

2.4.1 Modelos de Linguagem de Grande Escala (LLM)

Os Modelos de Linguagem de Grande Escala (LLM), como o GPT (*Generative Pre-trained Transformer*) da OpenAI, são uma das inovações mais notáveis no campo da IA. O progresso no processamento de linguagem natural (NLP - *Natural Language Processing*) evoluiu de modelos estatísticos para modelos neurais, alimentados por terabytes de dados, tornando-os capazes de processar e gerar textos de forma coerente e concisa (NAVEED et al., 2024).

2.4.1.1 Arquitetura e Funcionamento dos LLMs

Os LLMs baseiam-se na arquitetura de transformadores, que permite ao modelo processar dados sequenciais (como texto) de maneira eficiente e com alta precisão. Essa arquitetura utiliza mecanismos de atenção que ajudam o modelo a focar nas partes mais relevantes do texto durante a geração de respostas. Através de um processo de pré-treinamento e ajuste fino (*fine-tuning*), esses modelos aprendem a prever a próxima palavra em uma sequência, resultando em uma capacidade surpreendente de gerar textos coerentes e contextualmente relevantes.

2.4.1.2 Aplicações dos LLMs

Os modelos de linguagem de grande porte têm uma vasta gama de aplicações em diversos setores. Um dos principais usos é em assistentes virtuais, onde são capazes de automatizar o atendimento ao cliente, oferecendo respostas precisas e contextuais a perguntas feitas pelos usuários. Além disso, esses modelos têm se mostrado eficazes na criação de conteúdo, facilitando a geração de artigos, relatórios e outros materiais escritos com base em dados fornecidos.

Outra aplicação relevante é na análise de sentimentos, em que os LLMs são utilizados para interpretar emoções e opiniões expressas em textos, sendo especialmente úteis no monitoramento de redes sociais e no processamento de dados. Eles também desempenham um papel importante na tradução automática, melhorando a precisão e a fluidez da tradução de textos entre diferentes idiomas, proporcionando resultados mais naturais.

2.4.1.3 Redes Neurais (ANN - *Artificial Neural Network*)

Segundo (GOODFELLOW; BENGIO; COURVILLE, 2016) as redes neurais são modelos computacionais inspirados no funcionamento do cérebro humano, compostas por camadas de neurônios artificiais interconectados. Cada neurônio realiza operações matemáticas simples, processando os dados de entrada e propagando-os através da rede.

A principal característica das redes neurais é sua capacidade de aprender com os dados, ajustando os pesos das conexões entre os neurônios por meio de algoritmos de aprendizado, como o gradiente descendente.

Esses modelos têm sido amplamente aplicados em áreas como reconhecimento de imagens, processamento de linguagem natural e previsão de séries temporais, tornando-se uma ferramenta essencial em projetos de inteligência artificial.

2.4.1.4 Deep Learning

Deep Learning (DL) é um subcampo da inteligência artificial que foca em algoritmos inspirados na estrutura e função do cérebro. O termo *deep* refere-se às várias camadas da rede neural que contribuem para o aprendizado. Enquanto as redes neurais simples podem consistir de uma ou duas camadas ocultas, as redes profundas podem ter dezenas ou até centenas de camadas, permitindo a modelagem de dados complexos com alta precisão. Além disso, os inputs de características em redes simples são normalmente vetores, enquanto em redes profundas esses inputs podem ser bidimensionais, como imagens, ou até mesmo tridimensionais, dependendo da aplicação. Essas características tornam os modelos baseados em DL, quando corretamente treinados, proeminentes em desafios de classificação e regressão (SARKER, 2021).

Existem atualmente diversas técnicas de *Deep Learning*, entre as quais podemos destacar os modelos MLP (*Multi-Layer Perceptron*) e CNN (*Convolutional Neural Network*). Os modelos MLP, como exemplificado na Figura 4, são redes neurais totalmente conectadas que utilizam funções de ativação como ReLU, Tanh e Sigmoid. Eles são treinados usando o algoritmo de backpropagation, ou retropropagação, que consiste na reutilização do erro do modelo em camadas intermediárias ou de entrada para recalcular os pesos da rede e minimizar a função de perda, que mede a precisão das estimativas do modelo em relação aos valores reais. Os modelos MLP são comumente utilizados em sistemas de classificação binária, onde a resposta é geralmente booleana (Sim ou Não) (PECULIAR CODING ENDEAVOURS, 2019).

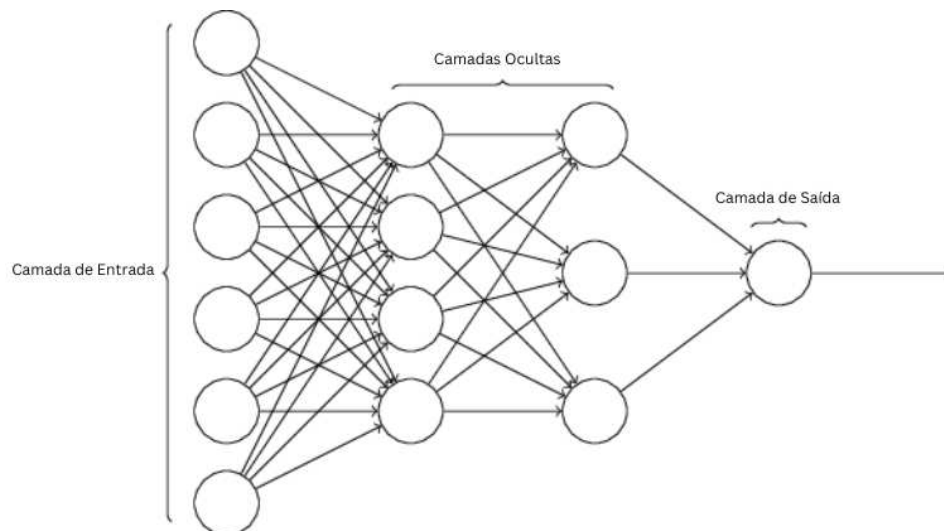


Figura 4 – Modelo MLP (Multi-Layer Perceptron). (PECULIAR CODING ENDEAVOURS, 2019)

Apesar de terem uma alta precisão em tarefas de classificação, os modelos MLP são pouco eficientes quando é necessário trabalhar com matrizes multidimensionais, como imagens, que são construídas por dados ordenados espacialmente. Por não considerarem tais propriedades espaciais, os modelos MLP não são tão eficientes para esse tipo de classificação quanto os

modelos CNN (SARKER, 2021).

Os modelos CNN são baseados na utilização de duas camadas principais: camadas de convolução e camadas de pooling. A camada de convolução é responsável por localizar padrões dentro de uma imagem por meio do escaneamento da imagem em quadrantes, aplicando a metodologia de convolução. Nesse processo, cada pixel do quadrante é multiplicado pelo valor do pixel correspondente no kernel, ou filtro, gerando um mapa de características. O resultado é somado para encontrar padrões e relações em cada parte específica da imagem (PECULIAR CODING ENDEAVOURS, 2019). Esses resultados criam um novo vetor bidimensional a partir da imagem original. A Figura 5 explicita o funcionamento dessa camada.




Figura 5 – Modelo CNN (Convolutional Neural Network) - Camada Convolucional. (PECULIAR CODING ENDEAVOURS, 2019)

Enquanto a camada de convolução é responsável por aprofundar a imagem original a partir da aplicação de filtros, a camada de pooling é responsável por reduzir a altura e largura da imagem original. Esse processo se assemelha ao processo utilizado na camada de convolução, onde a imagem é analisada por quadrantes que se movimentam por toda a imagem original de acordo com o *stride* (quantidade de pixels que o filtro se desloca sobre a imagem) definido, porém é aplicado o conceito de *max pooling*, que retorna o maior valor dentro do quadrante analisado, como visto na Figura 8.




Figura 6 – Modelo CNN (Convolutional Neural Network) - Camada Pooling. (Autor)

2.5 Classificação de Intenções de Texto com BERT via Treinamento Supervisionado

BERT (*Bidirectional Encoder Representations from Transformers*) é um modelo de linguagem desenvolvido por pesquisadores do departamento de inteligência artificial da Google em 2018. Esse modelo é particularmente eficaz devido à sua capacidade de considerar o contexto bidirecional das palavras em uma frase, o que permite uma compreensão mais profunda do significado (BARATTO, 2022). Diferente dos modelos direcionais, que processam o texto de maneira sequencial (da esquerda para a direita ou vice-versa), o BERT lê a sequência completa de palavras simultaneamente em ambas as direções. Isso permite que o modelo compreenda o contexto de uma palavra com base em seu entorno completo (tanto à esquerda quanto à direita da palavra) (DEVLIN et al., 2019)



Figura 7 – Mecanismo de Auto-Atenção. (BARATTO, 2022)

Na Figura 7, temos um exemplo do mecanismo de auto-atenção utilizado por diversos

modelos de linguagem natural, esse mecanismo determina o peso da relação contextual entre todas as palavras de uma sequência de entrada. Isso permite que o modelo foque em partes específicas da entrada que são mais relevantes para determinar o contexto.

2.5.0.1 *Transformer*

Transformers são uma arquitetura de rede neural que tem ganhado bastante relevância na área de processamento de linguagem natural (NLP). Eles são compostos por blocos de transformadores empilhados, cada um dos quais é uma rede multilayer que mapeia sequências de vetores de entrada para sequências de vetores de saída de mesma extensão. A principal inovação dos *transformers* é o mecanismo de autoatenção (*self-attention*), que permite à rede extrair e usar informações de contextos arbitrariamente grandes de maneira direta (JURAFSKY; MARTIN, 2023).

2.5.0.2 Tensores

Em matemática e ciência da computação, um tensor é uma generalização de escalares, vetores e matrizes para um espaço com mais de duas dimensões (RABANSER; SHCHUR; GÜNNEMANN, 2017). Tecnicamente, um tensor é uma entidade matemática que descreve uma relação linear entre objetos geométricos em um espaço vetorial. No contexto do aprendizado de máquina e redes neurais, os tensores são a estrutura de dados fundamental para representar e manipular dados.

Os dados de entrada em muitos problemas de aprendizado de máquina são naturalmente multidimensionais, como imagens (2D), áudio (1D) e texto (sequências de palavras). Esses dados são representados como tensores para alimentar os modelos de aprendizado de máquina.

2.5.0.3 Época (*Epoch*)

As épocas (ou *epochs*) são um conceito fundamental no treinamento de redes neurais. Uma época é definida como uma passagem completa sobre todo o conjunto de dados de treinamento. Durante o treinamento, os dados são divididos em pequenos subconjuntos chamados de minibatches, e o modelo é atualizado após cada minibatch. Quando todos os minibatches foram usados uma vez, dizemos que uma época foi completada.

A importância das épocas reside no fato de que elas determinam quantas vezes o algoritmo de aprendizado verá o conjunto de dados de treinamento inteiro. Se o número de épocas for muito baixo, o modelo pode não aprender suficientemente bem os padrões nos dados, levando ao problema conhecido como underfitting (subajuste). Por outro lado, se o número de épocas for muito alto, o modelo pode aprender não apenas os padrões, mas também o ruído nos dados

de treinamento, resultando em *overfitting* (sobreajuste), onde o modelo não generaliza bem para novos dados não vistos (AFAQ; RAO, 2020).

Durante o treinamento, dois tipos de erros são monitorados: o erro de treinamento e o erro de validação. O erro de treinamento indica o quão bem o modelo está aprendendo os dados de treinamento, enquanto o erro de validação indica o quão bem o modelo generaliza para um conjunto de dados de validação que não foi usado no treinamento. Um sinal claro de *overfitting* é quando o erro de validação começa a aumentar enquanto o erro de treinamento continua a diminuir. Neste ponto, a técnica de *early stopping* (parada antecipada) pode ser utilizada para interromper o treinamento antes que o modelo comece a se ajustar excessivamente ao ruído dos dados de treinamento (AFAQ; RAO, 2020).

Portanto, determinar o número adequado de épocas é uma parte essencial do processo de treinamento de uma rede neural, e deve ser feito cuidadosamente, levando em consideração os erros de treinamento e validação para evitar *underfitting* e *overfitting* (AFAQ; RAO, 2020).

2.5.0.4 Tokenização e *Embedding*

A Tokenização é uma etapa fundamental durante o treinamento de um modelo de LLM. Ela é definida como o processo de dividir um texto em partes menores chamadas de tokens. Esses tokens podem ser palavras individuais, subpalavras ou até mesmo caracteres, dependendo do método de tokenização utilizado (NAVEED et al., 2024).

Após a tokenização, os tokens precisam ser convertidos em representações numéricas para que possam ser processados pelo modelo. Essa conversão é feita por meio de *embeddings*, que são vetores densos de números que representam os tokens de maneira que preservem sua semântica no espaço vetorial.

2.5.0.5 Taxa de Aprendizado (*Learning Rate*) e Tamanho de Lote (*Batch Size*)

A Taxa de Aprendizado (*Learning Rate*) define a velocidade com que o modelo ajusta seus parâmetros em resposta ao erro estimado durante o processo de treinamento. Uma taxa de aprendizado muito alta pode fazer o modelo saltar para longe do valor ideal, enquanto uma taxa muito baixa pode tornar o processo de convergência lento ou até estagnado.

O Tamanho do Lote (*Batch Size*) refere-se ao número de amostras de treinamento processadas antes da atualização dos parâmetros do modelo. Um tamanho de lote menor permite atualizações mais frequentes, mas com maior variabilidade, enquanto tamanhos maiores proporcionam uma estimativa mais estável, porém com menos atualizações por época.

Existem ainda outros fatores que influenciam o resultado do treinamento de um modelo, como a proporção entre os dados de treinamento e os dados de teste, bem como o volume, a qualidade e a distribuição desses dados. Segundo Goodfellow et al. (GOODFELLOW;

BENGIO; COURVILLE, 2016), a escolha cuidadosa do conjunto de dados e sua preparação são cruciais, pois a variabilidade nos dados pode afetar significativamente a performance do modelo. A amostragem adequada e a diversidade nos dados são essenciais para garantir que o modelo aprenda a generalizar bem e não apenas a memorizar os dados de treinamento.

2.5.1 Integração do *Machine Learning* com Energia Solar

Assim como os modelos de *Machine Learning* e interfaces de inteligência artificial vêm evoluindo ao longo dos últimos anos, o setor de produção energética renovável vem ganhando mais espaço e atenção. A energia fotovoltaica tem se destacado como um dos principais agentes na transição da matriz energética de diversos países, como é possível ver no gráfico abaixo:




Figura 8 – Evolução da Capacidade Elétrica de Fontes Renováveis.
(International Energy Agency (IEA), 2024)

Esse desenvolvimento é resultado não somente da mudança de normas e legislações para incentivar a utilização desses meios de produção, mas também do aperfeiçoamento das tecnologias envolvidas nesse setor. Os modelos de ML, tem potencial de causar grande impacto, melhorando o controle de recursos, eficiência, manutenção, democratizando e promovendo o conhecimento a respeito do assunto. Esses benefícios são consequência da capacidade dos modelos atuais em analisar grandes volumes de dados, retornando estimativas capazes de auxiliar na previsão de fontes renováveis, que são caracterizadas por sua intermitência, capacidade de analisar imagens, que auxiliam na detecção de falhas, necessidade de manutenção, etc, bem como sua capacidade de interpretar e transmitir conhecimento de forma clara e adaptável a cada

usuário (RANE; CHOUDHARY SAURABH P., 2024).

Técnica	Descrição	Aplicações em Energias Renováveis
Redes Neurais Artificiais (ANNs)	Modelos inspirados na estrutura neural do cérebro, usados para reconhecer padrões e fazer previsões.	Previsão de produção e uso de energia; Otimização do desempenho de sistemas de energia renovável.
Máquinas de Vetores de Suporte (SVMs)	Algoritmos de aprendizado supervisionado para classificação de dados e análise de regressão.	Categorização de tipos de geração de energia; Previsão de padrões de demanda energética.
Árvores de Decisão	Modelos estruturados em árvore para tomada de decisão e análise de resultados.	Previsão de consumo de energia; Manutenção preditiva em equipamentos de energia renovável.
Florestas Aleatórias	Conjuntos de árvores de decisão para melhorar a precisão de classificação e regressão.	Melhoria da precisão em previsões de carga energética; Avaliação de desempenho de sistemas de energia renovável.
Aprendizado por Reforço (RL)	Métodos de aprendizado que otimizam ações recompensando comportamentos desejáveis ao longo do tempo.	Gestão em tempo real de redes elétricas; Controle autônomo de soluções de armazenamento de energia.
Algoritmos Genéticos (GAs)	Técnicas de otimização inspiradas em processos de seleção natural.	Design de sistemas de energia renovável eficientes; Otimização de layouts de parques eólicos.
Aprendizado Profundo (DL)	Redes neurais avançadas com múltiplas camadas para previsões mais precisas e reconhecimento de padrões.	Melhoria da precisão na previsão de energia solar; Identificação de tendências em dados energéticos extensos.

Tabela 1 – Técnicas de IA e suas aplicações em energias renováveis. (RANE; CHOUDHARY SAURABH P., 2024)

Na Tabela 1, temos alguns exemplos de como as técnicas de *Machine Learning* atuais vêm sendo utilizadas em benefício das energias renováveis. Para o setor fotovoltaico, a IA é essencial para aumentar a eficácia dos sistemas de energia solar.

Prever as flutuações na radiação solar causadas por padrões climáticos variados é um desafio significativo no campo da energia solar. Segundo (RANE; CHOUDHARY SAURABH P., 2024), algoritmos de ML, especialmente modelos de aprendizado profundo, são empregados para prever a irradiância solar com precisão. Esses modelos utilizam dados climáticos passados, imagens de satélite e informações meteorológicas atuais para prever a produção de energia solar, auxiliando na organização e no controle aprimorado dos ativos de energia solar.

Além disso, o uso de IA para prever as necessidades de manutenção de painéis solares é uma aplicação importante. Modelos de ML examinam informações de sensores integrados nos painéis solares para identificar anormalidades e prever possíveis falhas. Essa estratégia reduz o tempo em que as instalações solares ficam inoperantes e os custos de manutenção, ajudando a maximizar o desempenho e a vida útil (RANE; CHOUDHARY SAURABH P., 2024).

3 METODOLOGIA

Este trabalho utiliza três vertentes principais para alcançar os resultados propostos: um modelo pré-treinado, utilizando técnicas de NPL, para detectar a intenção do usuário em realizar um dimensionamento fotovoltaico; integração com a interface da OpenAI, ajustada especificamente para responder a perguntas gerais dos usuários relacionadas ao tópico de energia solar; e um algoritmo de dimensionamento que, com base nas informações fornecidas pelo usuário, identifica o conjunto célula + inversor fotovoltaico com o melhor tempo de *payback*.

Neste capítulo, serão detalhadas as metodologias empregadas no desenvolvimento dos componentes, bem como os aspectos relacionados ao seu desempenho e funcionamento.

3.0.1 Solução Proposta

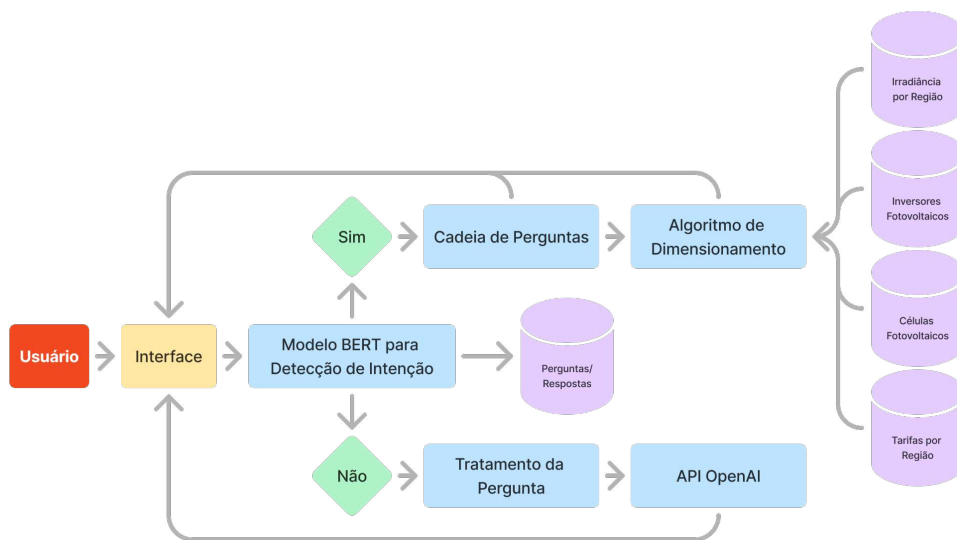


Figura 9 – Modelo Proposto. (Autor)

O diagrama acima demonstra o modelo proposto neste trabalho. A entrada do usuário, recebida pela interface, é direcionada para um modelo BERT pré-treinado, projetado para identificar se uma determinada sequência de entrada está associada ao interesse do usuário em realizar o projeto de uma planta fotovoltaica. Caso a resposta seja positiva, uma cadeia de perguntas é direcionada para a interface, e as respostas do usuário são coletadas, tratadas e enviadas para o algoritmo de dimensionamento, que, por sua vez, é alimentado com um

conjunto de dados referentes a tarifas, irradiação solar por região e componentes fotovoltaicos. Utilizando esses dados e as informações fornecidas pelo usuário, o algoritmo retorna para a interface o conjunto fotovoltaico mais otimizado em termos de investimento financeiro para atender à demanda proposta.

No segundo caso, quando a resposta do usuário não está relacionada à necessidade ou interesse no dimensionamento, a entrada é tratada e, se estiver relacionada à energia solar, é enviada para a interface de Programação de Aplicação (API) da OpenAI, que é responsável por analisar e responder à solicitação do usuário.

As respostas geradas pelo modelo são salvas em um banco de dados para serem reutilizadas em seu treinamento, com o objetivo de melhorar sua precisão.

3.1 Configuração do Modelo Classificatório e Treinamento

O processo de treinamento do modelo envolve etapas importantes, como a preparação dos dados, que inclui a tokenização, conversão em tensores e organização no *DataLoader*. O *DataLoader* facilita a iteração ao dividir os dados em blocos, embaralhá-los e otimizar o uso de memória com carregamento paralelo. Neste projeto foi utilizado o PyTorch, uma biblioteca de aprendizado profundo de código aberto desenvolvida pelo Facebook, na versão 2.3.1, para a criação do *DataLoader*, além de auxiliar no treinamento e verificação de desempenho do modelo.

Além disso, o treinamento envolve um escopo de parâmetros que devem ser ajustados para atingir o resultado necessário, que pode variar de acordo com o objetivo do modelo treinado. Os medidores de desempenho do treinamento dependem de diversos fatores, como o volume de dados de treinamento, a qualidade desses dados e a quantidade de épocas de treinamento. Abaixo uma lista dos principais indicadores de desempenho de modelos de *Machine Learning* que forem utilizados nesse projeto:

- **Training Accuracy:** Mede a proporção de previsões corretas feitas pelo modelo no conjunto de dados de treinamento. Uma acurácia de treinamento mais alta indica que o modelo está aprendendo bem os padrões nos dados de treinamento.
- **Training Loss:** Mede o erro médio das previsões do modelo no conjunto de dados de treinamento. Uma perda de treinamento mais baixa indica que o modelo está minimizando a diferença entre suas previsões e os valores reais.
- **Validation Accuracy:** Mede a proporção de previsões corretas feitas pelo modelo no conjunto de dados de validação. Uma acurácia de validação mais alta indica que o modelo está generalizando bem para novos dados que não foram usados durante o treinamento.
- **Precision:** A precisão mede a relação de predições verdadeiras positivas, em relação ao total de predições que resultaram em positivas.

- **Recall:** O recall mede a relação de predições verdadeiras positivas em relação ao total de predições realmente positivas. Isso mostra a capacidade do modelo em identificar instâncias realmente positivas.
- **F1 Score:** O F1 Score é a média harmônica da precisão e do recall. É uma métrica balanceada que considera tanto os falsos positivos quanto os falsos negativos.




Figura 10 – Resultado do Treinamento: 10 épocas, 32 labels positivas, 24 negativas (Autor)

Na Figura 10 observamos os resultados do treinamento com 10 épocas, utilizando um conjunto de dados composto por 32 labels positivas e 24 labels negativas. Isso significa que, do total de 56 amostras, 32 resultam em uma saída positiva, enquanto 24 resultam em uma saída negativa. Este número de amostras é relativamente pequeno dentro do escopo de aprendizado de máquina, o que pode limitar a capacidade do modelo de generalizar para novos dados. Os resultados obtidos mostram um erro médio (*Training Loss*) e uma precisão de treinamento (*Training Accuracy*) satisfatórios, porém, a precisão no conjunto de dados de validação (*Validation Accuracy*) indica uma eficiência baixa do modelo. Este comportamento sugere que o modelo pode estar sofrendo de *overfitting*, onde ele se ajusta bem aos dados de treinamento, mas não consegue generalizar para novos dados.




Figura 11 – Resultado do Treinamento: 5 épocas, 32 labels positivas, 24 negativas (Autor)

Na Figura 11, apresentamos um cenário semelhante, mas com apenas 5 épocas de treinamento. Como resultado, o modelo demonstra um aumento no erro médio. Isso pode indicar que menos épocas de treinamento não foram suficientes para o modelo aprender os padrões dos dados de forma eficaz, o que comprometeu seu desempenho.




Figura 12 – Resultado do Treinamento: 10 épocas, 44 labels positivas, 42 negativas (Autor)




Figura 13 – Resultado do Treinamento: 5 épocas, 44 labels positivas, 42 negativas (Autor)

Já as Figuras 12 e 13, mostram um desempenho significativamente melhorado. Isso se deve ao aumento no volume de dados, com 44 labels positivas e 42 labels negativas, totalizando 86 amostras. Além disso, a proporção entre labels positivas e negativas está mais equilibrada, passando de uma razão de aproximadamente 1.33 nas figuras iniciais para 1.05 nas figuras posteriores. Esse equilíbrio reduz a chance de o modelo se tornar enviesado, favorecendo uma classe sobre a outra. A combinação de um conjunto de dados mais equilibrado e maior volume de informações para treinamento resultou em indicadores de desempenho mais robustos, evidenciando um melhor ajuste do modelo aos dados sem comprometer sua capacidade de generalização.

A Tabela 2 a seguir apresenta alguns resultados de uma série de treinamentos realizados com os seguintes ajustes de hiperparâmetros: Épocas = [5, 7, 10], Taxa de Aprendizado = [1e-5, 2e-5, 3e-5] e Lotes = [16, 24, 32].

Epochs	Learning Rate	Batch Size	Epoch	Training Loss	Training Accuracy	Validation Accuracy	F1 Score	Precision	Recall
10	2×10^{-5}	16	9	0.32	0.93	0.78	0.75	0.60	1.00
10	3×10^{-5}	16	6	0.32	0.90	0.72	0.71	0.55	1.00
7	3×10^{-5}	16	7	0.40	0.85	0.72	0.71	0.55	1.00
10	2×10^{-5}	16	8	0.40	0.84	0.78	0.75	0.60	1.00
7	2×10^{-5}	24	6	0.43	0.85	0.72	0.67	0.56	0.83
7	3×10^{-5}	32	5	0.43	0.81	0.78	0.75	0.60	1.00
7	2×10^{-5}	16	5	0.43	0.87	0.72	0.71	0.55	1.00
10	2×10^{-5}	16	7	0.44	0.88	0.72	0.71	0.55	1.00
7	3×10^{-5}	16	6	0.44	0.81	0.78	0.67	0.67	0.67
10	1×10^{-5}	16	7	0.45	0.82	0.78	0.75	0.60	1.00
10	2×10^{-5}	16	5	0.45	0.82	0.72	0.67	0.56	0.83
7	2×10^{-5}	24	5	0.46	0.85	0.72	0.67	0.56	0.83
7	2×10^{-5}	16	5	0.46	0.79	0.67	0.67	0.50	1.00
10	2×10^{-5}	32	10	0.47	0.85	0.72	0.67	0.56	0.83
10	2×10^{-5}	24	6	0.47	0.79	0.72	0.67	0.56	0.83
10	2×10^{-5}	16	6	0.47	0.85	0.78	0.75	0.60	1.00
10	2×10^{-5}	24	7	0.48	0.85	0.78	0.75	0.60	1.00
5	2×10^{-5}	16	4	0.49	0.81	0.72	0.67	0.56	0.83
10	2×10^{-5}	32	8	0.51	0.81	0.72	0.71	0.55	1.00
5	2×10^{-5}	16	5	0.52	0.85	0.67	0.57	0.50	0.67
10	2×10^{-5}	16	6	0.52	0.74	0.78	0.75	0.60	1.00
7	2×10^{-5}	16	4	0.52	0.74	0.72	0.55	0.60	0.50
10	2×10^{-5}	16	4	0.52	0.82	0.67	0.67	0.50	1.00
7	2×10^{-5}	32	4	0.53	0.81	0.78	0.71	0.62	0.83
10	2×10^{-5}	24	6	0.54	0.74	0.78	0.75	0.60	1.00
7	2×10^{-5}	16	6	0.55	0.82	0.78	0.75	0.60	1.00
7	2×10^{-5}	24	4	0.55	0.76	0.78	0.75	0.60	1.00
10	2×10^{-5}	24	5	0.55	0.69	0.72	0.71	0.55	1.00
7	2×10^{-5}	16	4	0.56	0.79	0.78	0.75	0.60	1.00
5	2×10^{-5}	24	4	0.56	0.76	0.67	0.67	0.50	1.00

Tabela 2 – Métricas de Treinamento (Autor)

Seguindo os resultados observados nos testes realizados e considerando que o modelo proposto busca identificar a intenção do usuário em realizar uma ação (dimensionamento de uma planta solar), é crucial alcançar um *F1 Score* equilibrado. Por um lado, é essencial ter precisão na previsão de verdadeiros positivos, garantindo que as ações sejam direcionadas a usuários com real intenção. Por outro lado, é importante também capturar uma gama mais ampla de usuários, mesmo que alguns possam não ter a intenção no momento, resultando em falsos positivos (*Recall*).

Portanto, como observado, os hiperparâmetros que proporcionam um resultado equilibrado e adequado para o problema proposto são: Épocas = 10, Taxa de Aprendizado = 2×10^{-5} e Tamanho do Lote = 16. Esses valores resultam em um *Training Loss* de 0.32, *Training Accuracy* de 0.93 e *Validation Accuracy* de 0.78, indicando que o modelo está aprendendo bem nos dados de treinamento e mantendo um bom desempenho no conjunto de validação.

3.2 Integração com a API da OpenAI

Para a integração com a API da OpenAI foi utilizada a biblioteca LangChain na versão 0.2.3 com o modelo de linguagem GPT-3.5. LangChain é uma biblioteca de código aberto que facilita o desenvolvimento de aplicativos baseados em modelos de linguagem, como os

fornecidos pela OpenAI e outros modelos de IA.

O primeiro passo do processo é o carregamento do conjunto de respostas previamente determinadas, que serão utilizadas como referência no processo geracional do modelo. Essas respostas são transformadas em embeddings através da classe disponibilizada pela LangChain, `OpenAIEmbeddings`. Os *embeddings* são então armazenados em um banco de dados vetorial utilizando FAISS, que facilita a busca por similaridade. Isso permite que o sistema identifique quais respostas anteriores são mais relevantes para a nova consulta do cliente.

A geração da resposta é orientada por um `PromptTemplate`, também parte da biblioteca LangChain, que garante que o assistente siga um conjunto de regras claras. O assistente deve, por exemplo, se esforçar para dar respostas curtas e diretas, imitando o estilo e tom das melhores respostas anteriores. Se as respostas anteriores não forem diretamente aplicáveis, ele deve buscar criar uma resposta relevante, mantendo a mesma estrutura e lógica. O *template* também contém uma instrução específica: se o cliente demonstrar interesse em realizar o dimensionamento de uma planta fotovoltaica, o assistente deve guiá-lo a fazer essa solicitação diretamente no chat.

Essa integração oferece uma série de possibilidades interessantes. Além de permitir que o assistente aprenda com as interações anteriores e melhore sua eficiência ao responder a perguntas, ela também possibilita a personalização das respostas de acordo com as necessidades específicas de cada cliente. Isso é particularmente útil no contexto de energia solar, onde perguntas técnicas podem ser comuns, e o assistente deve ser capaz de fornecer orientações precisas.

3.3 Algoritmo de Dimensionamento

Para o dimensionamento dos componentes do projeto, foram utilizadas as informações fornecidas pelo usuário, que ao serem processadas por um algoritmo de dimensionamento, retornam o conjunto com o melhor custo benefício que atende a demanda específica do cliente. Os resultados são gerados a partir da base de componentes carregada no modelo, que foi desenvolvido de acordo com a seguinte lógica.

3.3.1 Carregamento das Bases

A primeira etapa do algoritmo é realizar o carregamento das bases de dados que servirão como referência no processo de dimensionamento.

A Base de Irradiação contém informações sobre a irradiação solar média global horizontal em diversos municípios brasileiros, sendo obtida diretamente do Atlas Brasileiro de Energia Solar.

A Base de Módulos e Inversores reúne dados, especificações técnicas e custos de diferentes modelos de células fotovoltaicas e inversores de várias marcas. Essa base foi construída

especificamente para este projeto, levando em consideração as informações mais relevantes para o objetivo proposto.

A Base de Tarifas traz dados relacionados às tarifas praticadas por diferentes concessionárias, levando em conta o estado e o tipo de consumidor, e foi obtida diretamente da ANEEL.

Vale ressaltar que, atualmente, essas bases são estáticas, ou seja, seus dados representam um instantâneo do momento em que foram adquiridas.

3.3.2 Cálculo do Consumo Energético Mensal

Em seguida é calculado o consumo médio mensal do cliente em $kWh/mês$, que deverá ser o consumo suprido pela planta solar. Para isso foi utilizado o seguinte princípio:

$$\text{Consumo Médio Mensal} = \left(\frac{\text{Valor da Conta de Energia}}{\text{Taxa Aplicada por kWh}} \right) - \text{Taxa Mínima} \quad (1)$$

Onde:

- **Valor da Conta de Energia:** Representa o valor total da conta de energia elétrica do cliente em reais (R\$).
- **Taxa Aplicada por kWh:** É a tarifa de energia elétrica cobrada por kWh (quilowatt-hora). Este valor é especificado em reais por kWh (R\$/kWh).
- **Taxa Mínima:** Refere-se ao consumo mínimo de energia (em kWh) que é cobrado pelo fornecedor de energia elétrica, independentemente do consumo real do cliente.

3.3.2.1 Razão para Subtrair a Taxa Mínima

- **Correção do Consumo Real:** Segundo a Resolução Normativa ANEEL nº 414/2010, existe uma tarifa mínima, também conhecida como custo de disponibilidade, que é um valor fixo cobrado independentemente do consumo, de acordo com o tipo de consumidor. Ao calcular o consumo médio mensal para determinar a demanda média que deverá ser suprida pela planta solar, é importante desconsiderar a faixa de consumo mínimo. Isso ocorre porque, independentemente da produção, o valor referente à tarifa mínima continuará a ser cobrado, conforme previsto pela Lei n.º 14.300/22.
- **Exemplo Prático:** Se a conta de energia é R\$ 100, a tarifa é R\$ 0,50/kWh e a taxa mínima é 50 kWh:

$$\text{Consumo Médio Mensal} = \left(\frac{100}{0,50} \right) - 50 = 200 - 50 = 150 \text{ kWh/mês}$$

Sem subtrair a taxa mínima, o cálculo seria:

$$\text{Consumo Médio Mensal} = \left(\frac{100}{0,50} \right) = 200 \text{ kWh/mês}$$

Este valor estaria superestimado, pois inclui a parte da tarifa mínima que não representa consumo a ser suprido.

3.3.3 Módulos Fotovoltaicos

Sabendo então o consumo mensal a ser suprido pela planta, podemos determinar a capacidade instalada para alcançar esse resultado. Primeiramente, é importante considerar a irradiância solar média da região em que o projeto será implantado, para isso, de acordo com o CEP fornecido pelo usuário, e utilizando os dados fornecidos pelo Atlas Brasileiro de Energia Solar, podemos chegar a essa contante.

A capacidade instalada é determinada de acordo com a seguinte fórmula:

$$\text{Capacidade Instalada} = \left(\frac{\text{Energia Gerada}}{\text{Tempo de Exposição} \times \text{Rendimento}} \right) \quad (2)$$

3.3.3.1 Energia Gerada

Essa componente representa a necessidade diária de energia que deve ser alcançada pela planta, esse valor é determinado pelo próprio consumo médio encontrado anteriormente.

$$\text{Energia Gerada} = \frac{\text{Consumo Médio Mensal}}{30} \quad (3)$$

3.3.3.2 Tempo de Exposição

O tempo de exposição representa o número de horas por dia que seriam equivalentes a uma irradiância constante de 1000 W/m^2 recebida pela superfície solar. A irradiância STC (Standard Test Conditions) representa as condições padrão de desempenho dos módulos solares fotovoltaicos. Utilizando-a como referência, podemos estabelecer de forma mais clara as perdas encontradas em testes e aumentar a precisão do dimensionamento dos sistemas solares.

$$\text{Tempo de Exposição} = \frac{\text{Irradiância Local}}{\text{Irradiância STC}} \quad (4)$$

Onde:

- **Irradiância Local:** É a quantidade média anual de energia solar recebida por unidade de área ao longo de um dia, medida em watt-hora por metro quadrado por dia

$(Wh/(m^2 \cdot dia))$.

- **Irradiância STC:** Refere-se à irradiância sob Condições Padrão de Teste (*Standard Test Conditions*), fixada em $1000 W/m^2$.

3.3.3.3 Fator de Redução (*Derating*)

O fator de redução é definido como a escala da potência de saída do painel solar para considerar diversas perdas que podem ocorrer no sistema fotovoltaico. Essas perdas incluem perdas no fio, devido a partículas de poeira, aumento de temperatura, sombreamento, e outras ineficiências. A compreensão e a aplicação correta dos fatores de redução são cruciais para o dimensionamento preciso e otimizado de plantas fotovoltaicas. A Tabela 3, apresenta alguns dos principais fatores de redução, além dos parâmetros definidos para este projeto e o intervalo médio desses fatores.

Fator de Redução	Multiplicador Potência de Saída	Range	Descrição
Potência Nominal do Módulo Fotovoltaico	0.95	0.88 - 0.96	Degradação inicial após exposição ao sol
Ajuste de Orientação	1.00	0.50 - 1.00	Ângulo ajustado para maximizar irradiação; limitado pela inclinação do telhado
Inversor e Transformador	0.95	0.88 - 0.96	Perdas na conversão e transformação
Incompatibilidade	0.98	0.88 - 0.96	Variações de corrente e voltagem entre módulos
Diodos e Conexões	0.99	0.97 - 0.99	Queda de tensão devido a diodos
Fiação DC	0.98	0.97 - 0.99	Perdas entre módulos e inversores
Fiação AC	0.99	0.98 - 0.99	Perdas entre inversores e medidor
Sujeira	0.95	0.30 - 0.99	Partículas na superfície do módulo bloqueando irradiação
Disponibilidade	0.98	0.98	Tempo de inatividade para manutenção
Sombreamento	0.95	0.00 - 1.00	Sombra de construções e vegetação
Rastreamento Solar	1.00	0.95 - 1.00	Maior exposição devido ao rastreamento solar
Idade	0.99	0.70 - 1.00	Redução da potência com o tempo

Tabela 3 – Fatores de Redução em Sistemas Fotovoltaicos (COURSES, 2020)

As condições ambientais e operacionais podem influenciar significativamente o multiplicador de potência dos módulos fotovoltaicos. Portanto, o dimensionamento preciso de uma planta solar deve levar em conta essas variáveis para garantir a máxima eficiência e precisão.

Para este estudo, consideraremos um multiplicador médio de 0.74, baseado em uma análise abrangente dos fatores de redução mencionados. Este valor médio reflete uma estimativa conservadora que incorpora as diversas perdas potenciais, oferecendo uma base sólida para o dimensionamento do sistema fotovoltaico.

3.3.4 Potência Instalada e Máxima Potência do Módulo

Para dimensionar um sistema fotovoltaico eficiente e capaz de atender à demanda energética estabelecida, é essencial determinar a potência instalada necessária. Este cálculo considera as condições pré-definidas, as possíveis perdas de eficiência e a demanda energética projetada.

A potência instalada, expressa em quilowatt-pico (kWp), pode ser calculada utilizando a seguinte fórmula:

$$\text{Potência Instalada (kWp)} = \frac{\text{Energia Gerada}}{\text{Tempo de Exposição} \times \text{Multiplicador de Potência}} \quad (5)$$

Onde:

- **Energia Gerada:** A quantidade de energia que se espera que o sistema produza.
- **Tempo de Exposição:** O número de horas de exposição solar recebida pelos módulos solares.
- **Multiplicador de Potência:** Um fator que considera as perdas de eficiência e a degradação dos módulos ao longo do tempo.

Além disso, é crucial calcular a máxima potência que cada módulo fotovoltaico pode fornecer sob condições específicas. A fórmula para a máxima potência do módulo, em watts (W), é:

$$\text{Máxima Potência Módulo (W)} = \frac{\text{Potência Nominal}}{1 + (\text{Temp. Local} - \text{Temp. Padrão}) \times \text{Coef. de Temp.}} \quad (6)$$

Onde:

- **Potência Nominal:** A potência nominal do módulo sob condições de teste padrão.
- **Temp. Local:** A temperatura média local onde o sistema será instalado.
- **Temp. Padrão:** A temperatura de teste padrão (geralmente 25°C).
- **Coef. de Temp.:** O coeficiente de temperatura do módulo, que indica a variação da potência com a temperatura.

Com esses valores em mãos, podemos determinar a quantidade de módulos necessários para atingir a potência instalada desejada. A fórmula para encontrar a quantidade de módulos é:

$$\text{Quantidade de Módulos} = \frac{\text{Potência Instalada}}{\text{Máxima Potência Módulo}} \quad (7)$$

Este cálculo nos permite planejar o número de módulos fotovoltaicos que devem ser instalados para garantir que a energia gerada seja suficiente para atender às necessidades energéticas projetadas, levando em consideração as condições ambientais e as características dos módulos.

3.3.5 Inversores de Potência

O dimensionamento do inversor a ser utilizado em uma planta fotovoltaica está diretamente relacionado à capacidade energética instalada. De forma prática, é preciso encontrar um inversor capaz de suportar uma potência, corrente e tensão de entrada superiores ou equivalentes às características totais do sistema. Alguns inversores são capazes de suportar diferentes quantidades de strings, que atuam fracionando a potência por grupos de módulos.

Para entender o dimensionamento, considere os seguintes parâmetros:

$$\text{Quantidade de Módulos por String} = \frac{\text{Quantidade de Módulos}}{\text{Quantidade de Strings}} \quad (8)$$

$$V_{\text{total}} = V_{\text{oc}} \times \text{Quantidade de Módulos por String} \quad (9)$$

$$I_{\text{total}} = I_{\text{sc}} \times \text{Quantidade de Strings} \quad (10)$$

Supondo um inversor que suporta 2 strings em um projeto de 10 módulos fotovoltaicos, onde cada módulo tem tensão de circuito aberto de 47,8V e corrente de curto-circuito de 10,01A, temos os seguintes cálculos:

3.3.5.1 Cálculos para Conexão em 1 String

- **Quantidade de Módulos por String:**

$$\text{Quantidade de Módulos por String} = \frac{10}{1} = 10 \quad (11)$$

- **Tensão Total do Sistema:**

$$\text{Tensão Total do Sistema} = 47,8V \times 10 = 478V \quad (12)$$

- **Corrente Total do Sistema:**

$$\text{Corrente Total do Sistema} = 10,01A \times 1 = 10,01A \quad (13)$$

3.3.5.2 Cálculos para Conexão em 2 Strings

- **Quantidade de Módulos por String:**

$$\text{Quantidade de Módulos por String} = \frac{10}{2} = 5 \quad (14)$$

- **Tensão Total do Sistema:**

$$\text{Tensão Total do Sistema} = 47,8V \times 5 = 239V \quad (15)$$

- **Corrente Total do Sistema:**

$$\text{Corrente Total do Sistema} = 10,01A \times 2 = 20,02A \quad (16)$$

3.3.5.3 Análise Comparativa

A utilização de diferentes quantidades de strings impacta diretamente a tensão e a corrente totais do sistema. No caso de uma única string, a tensão total é maior (478V), mas a corrente permanece a mesma (10,01A). Já com duas strings, a tensão é reduzida pela metade (239V), mas a corrente é duplicada (20,02A). Esse balanceamento é crucial para a escolha do inversor correto, garantindo que os parâmetros elétricos do sistema sejam compatíveis com as especificações do inversor.

A escolha entre uma ou duas strings depende das características do inversor e do projeto. Inversores que suportam múltiplas strings permitem uma maior flexibilidade no dimensionamento do sistema, facilitando a adaptação a diferentes configurações e otimizando o desempenho do sistema fotovoltaico.

3.4 Payback

A partir da lógica apresentada, podemos chegar ao fluxograma, apresentado na Figura 14, que descreve o princípio de funcionamento do algoritmo.

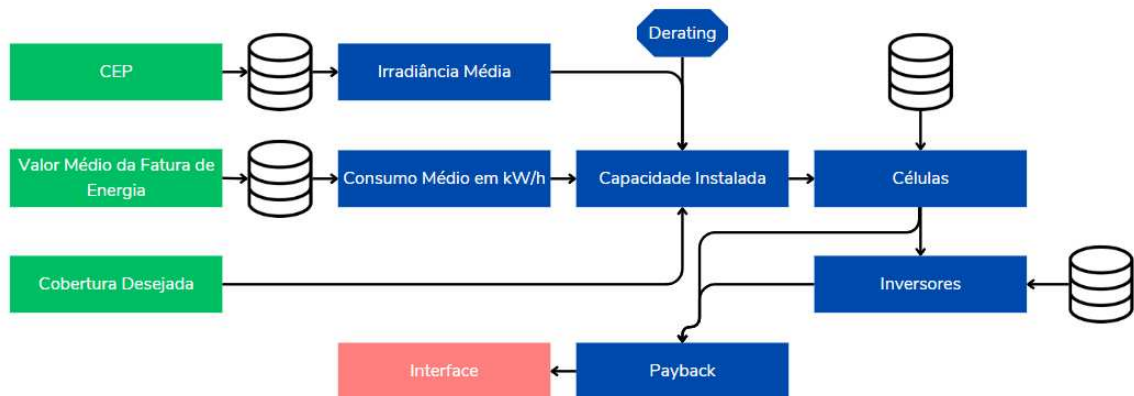


Figura 14 – Fluxograma do Algoritmo de Dimensionamento (Autor)

Seguindo o fluxograma apresentado, o *payback* é determinado de acordo com os possíveis conjuntos de células fotovoltaicas e inversores disponíveis nos bancos de dados, que atendem à necessidade apresentada pelo usuário. A partir dos custos envolvidos em cada possível projeto, é calculado o tempo de retorno do investimento, considerando a energia anual gerada com base na capacidade instalada do sistema fotovoltaico, a tarifa de energia elétrica vigente, o custo de manutenção anual e a degradação da produção de energia ao longo dos anos.

Também é levado em conta o valor mínimo mensal pago à concessionária. O fluxo de caixa anual é calculado subtraindo os custos de manutenção e o pagamento mínimo anual da receita gerada pela energia produzida.

A partir disso, o saldo acumulado é atualizado ano a ano até que o valor total investido seja recuperado, determinando o período de *payback*. O cálculo final ajusta o número de anos para refletir o saldo negativo restante no fluxo de caixa, obtendo assim uma estimativa precisa do tempo necessário para recuperar o investimento.

4 RESULTADOS

Durante os testes realizados o software teve uma ótima capacidade de resposta, fornecendo informações claras e objetivas a respeito do assunto proposto pelo usuário. Em relação ao modelo de identificação de interesse do usuário, em primeiros teste foi notado uma certa dificuldade durante a análise dos tópicos comentados pelo usuário, porém conforme a base de treinamento era carregada e aperfeiçoada com novas informações, esse desempenho melhorou de forma significativa. Na Figura 15, temos a visão inicial da interface desenvolvida, onde o usuário é recebido com uma breve mensagem de boas vindas para passar o contexto da aplicação.

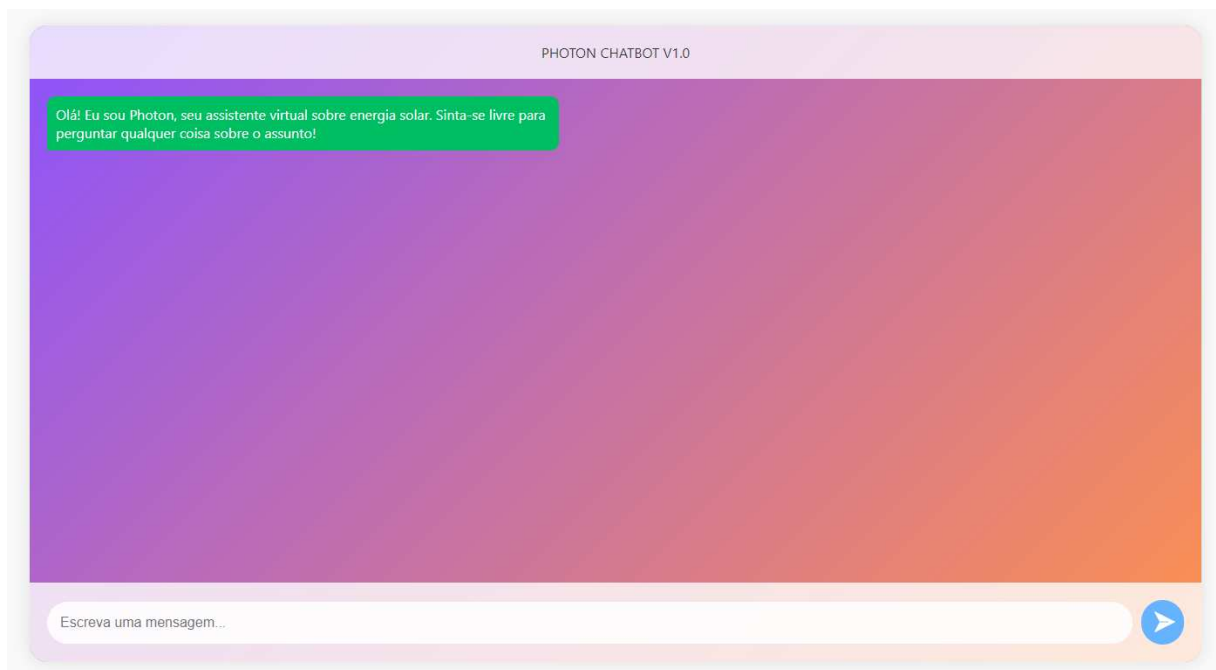


Figura 15 – Interface do ChatBot - Início. (Autor)

Devido a utilização da API da OpenAI, o tratamento de assuntos gerais se tornou eficiente, e a interação do usuário com o ChatBot pôde ficar mais dinâmica, e mesmo sem um grande volume de dados, podemos construir um modelo capaz de responder diversas perguntas relacionadas ao tópico deste trabalho, como também reconhecer aquelas que não estão relacionadas ao que o modelo se propõe. Na Figura 16, temos um exemplo de interação comum do usuário com o ChatBot.

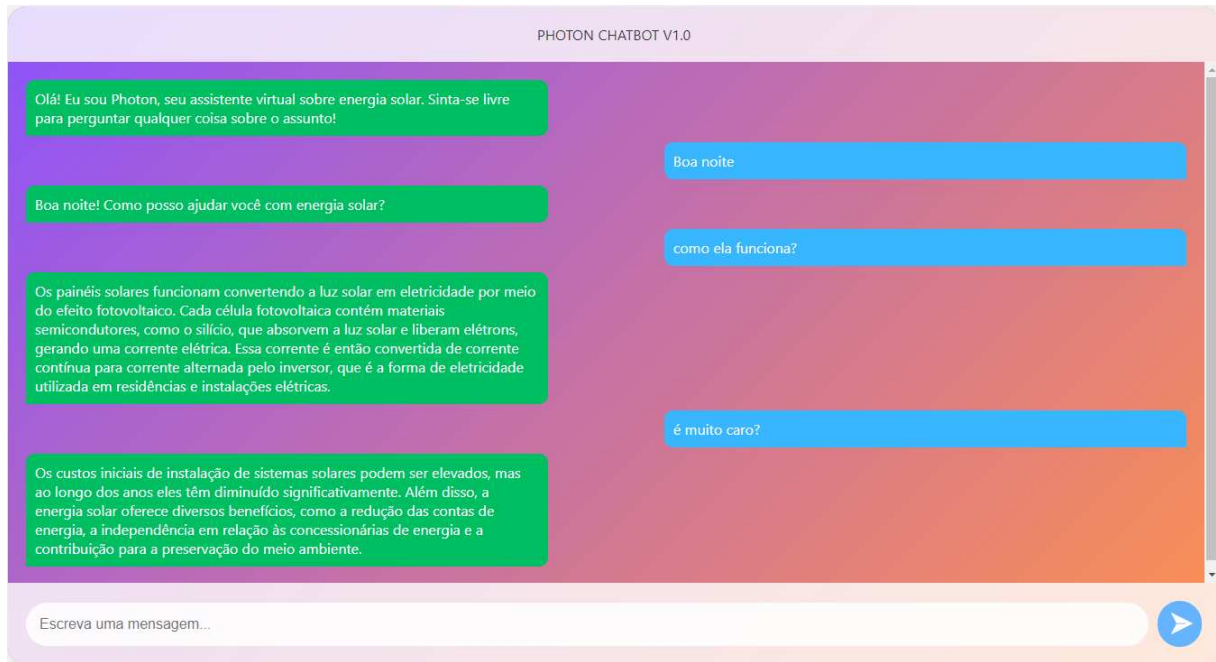


Figura 16 – Interface do ChatBot - Conversa. (Autor)

Na Figura 17, temos uma exemplificação do modelo classificatório, que interpreta a entrada do usuário como interesse no dimensionamento de um projeto e, a partir da confirmação do usuário, desencadeia uma série de perguntas que serão utilizadas para o cálculo.

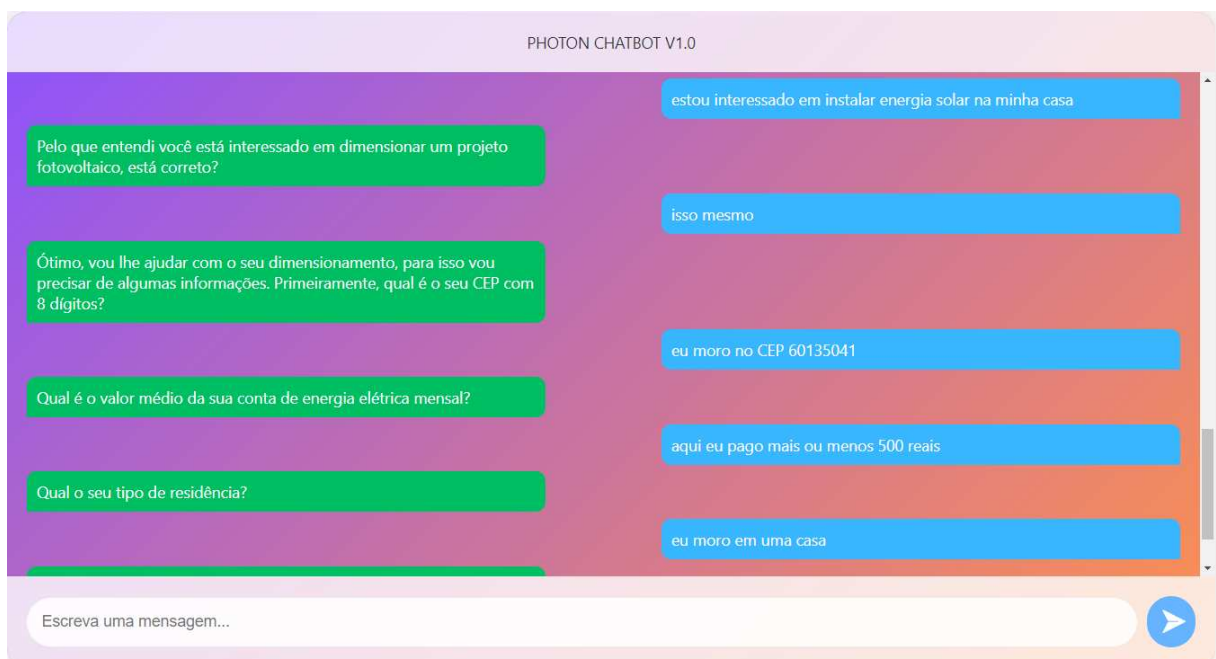


Figura 17 – Interface do ChatBot - Dimensionamento. (Autor)

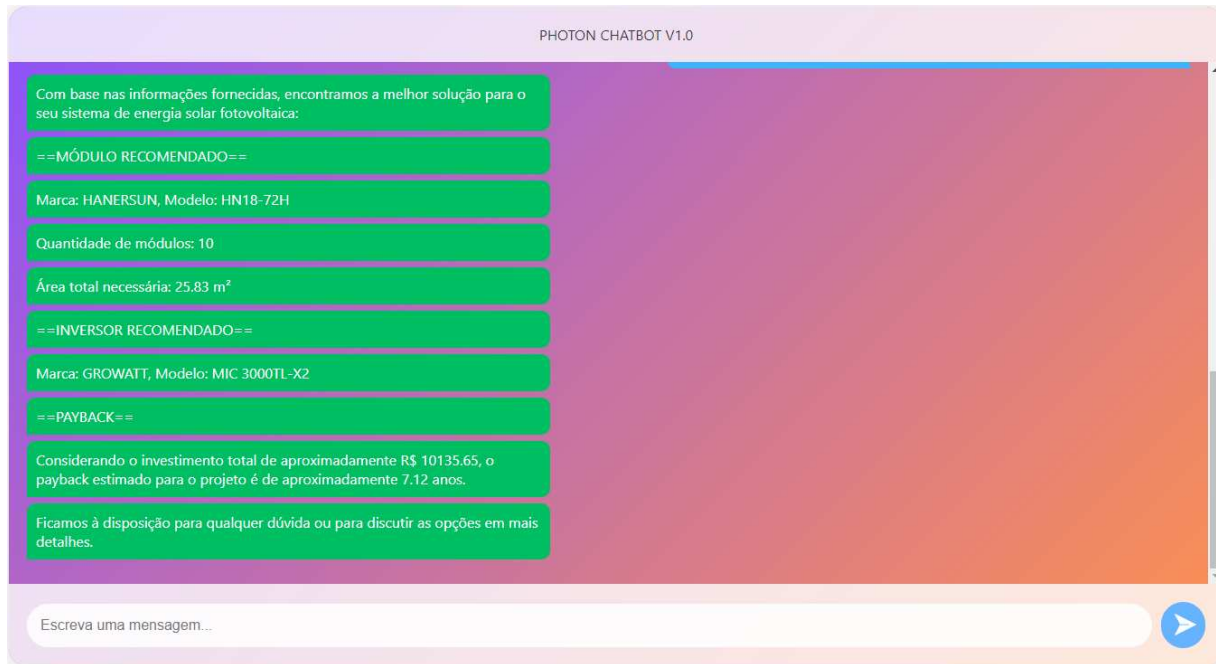


Figura 18 – Interface do ChatBot - Resposta de Dimensionamento. (Autor)

Utilizando bancos de dados de irradiância, tarifas, inversores e células fotovoltaicas, foi possível desenvolver projetos de acordo com as características fornecidas pelo usuário, além de estimar o payback para o projeto como visto na Figura 18, o que oferece maior clareza sobre o investimento.

Dessa forma, foi possível atingir os objetivos propostos no projeto. No entanto, devido ao uso de uma base de componentes construída manualmente, o modelo fica limitado aos conjuntos presentes nessa base. Com uma base de dados mais extensa, seria possível alcançar um ajuste mais refinado e preciso.

5 CONCLUSÃO

A tecnologia tem desempenhado um papel crucial na transformação da engenharia, oferecendo ferramentas e soluções que tornam os processos mais eficientes e precisos. A inteligência artificial (IA), em especial, possibilita a análise rápida e precisa de grandes volumes de dados, identificando padrões e oferecendo insights que seriam difíceis de alcançar manualmente. Essa capacidade já está sendo explorada em diversos setores da sociedade, com potencial para impactar positivamente o setor energético em várias frentes.

Como demonstrado neste projeto, apesar de lidarmos com um volume relativamente baixo de dados, foi possível desenvolver uma ferramenta capaz não só de interagir com o usuário, transmitindo conhecimentos e discutindo tópicos específicos relacionados ao escopo e aos objetivos do projeto, mas também de compreender as intenções do usuário. A partir da análise das entradas fornecidas, a ferramenta utiliza dados relevantes para dimensionar um sistema fotovoltaico que atenda às demandas apresentadas, otimizando tanto o tempo quanto os custos associados ao processo de dimensionamento.

Em suma, as possibilidades apresentadas pela integração dessas tecnologias são vastas, indo desde a transmissão de conhecimentos específicos de uma empresa ou instituição até a disponibilização de dados demográficos e sociais. Além disso, essa ferramenta pode ser empregada por profissionais da área de energia solar que buscam otimizar seu tempo e aprimorar o processo de dimensionamento. O campo da inteligência artificial, combinado com o setor de energia solar, apresenta um potencial significativo, e a exploração das sinergias entre essas tecnologias pode gerar resultados promissores.

6 TRABALHOS FUTUROS

Este projeto foi desenvolvido de forma experimental, utilizando um pequeno volume de dados para analisar e verificar as possibilidades da interface. Portanto, trabalhos futuros podem se concentrar no treinamento do modelo com um volume maior de dados, permitindo um desempenho superior e maior robustez nas previsões.

Testes em larga escala serão necessários para validar o potencial da ferramenta em diferentes cenários e condições reais de operação. Além disso, é essencial desenvolver uma base de dados mais abrangente e detalhada sobre módulos e inversores fotovoltaicos, possibilitando uma maior variedade de opções e configurações, bem como automatizar o processo de atualização das bases estáticas.

Outra área de foco é a implementação de novas variáveis que tornem o algoritmo de dimensionamento da planta fotovoltaica ainda mais preciso e customizável. Finalmente, a avaliação contínua do modelo com dados reais de usuários será fundamental para ajustar e refinar o algoritmo conforme necessário.

Com essas melhorias, espera-se que a ferramenta possa ser aplicada de maneira eficaz em contextos práticos e comerciais, oferecendo soluções precisas para o dimensionamento de sistemas de energia solar fotovoltaica.

REFERÊNCIAS

- AFAQ, S.; RAO, S. Significance of epochs on training a neural network. *International Journal of Scientific & Technology Research*, IJSTR, v. 9, n. 6, p. 485–488, 2020.
- AJIBADE, S.-S. M. et al. Machine learning applications in renewable energy (mlare) research: A publication trend and bibliometric analysis study (2012?2021). *Clean Technol.*, MDPI, v. 5, p. 497–517, 2023. Disponível em: <<https://doi.org/10.3390/cleantechnol5020026>>.
- BARATTO, G. J. *Comparação entre os modelos pré-treinados GPT-3 e BERT na estimativa de esforço de software por analogia a partir de requisitos textuais*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2022. Acesso em: 16 jul. 2024. Disponível em: <<https://www.tue.nl/>>.
- BOYD, J. *Microinverters vs String Inverters: An Honest Comparison*. 2024. Disponível em: <<https://www.penrithsolar.com.au/blog/microinverters-vs-string-inverters-an-honest-comparison/>>.
- CARVALHO, A. C. P. d. L. Ferreira de. Inteligência artificial: riscos, benefícios e uso responsável. *Estudos Avançados*, Universidade de São Paulo, v. 35, n. 101, p. 21–36, 2021.
- COURSES iPolytek O. E. *How to calculate how many solar modules you need (Solar Energy Course 2020 Part 8 of 12)*. 2020. Accessed: 2024-09-04. Disponível em: <<https://www.youtube.com/watch?v=GZS6PMfNPvE>>.
- CRESESB. *Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Brito*. 2024. <https://cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=321>. Acessado em: 1 de agosto de 2024.
- DEVLIN, J. et al. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2019. Disponível em: <<https://arxiv.org/abs/1810.04805>>.
- ENERGES. *Irradiação e Irradiância*. 2019. Disponível em: <<https://energes.com.br/diferenca-de-irradiancia-e-irradiacao/#:~:text=Irradiância%20representa%20o%20fluxo%20de,por%20unidade%20de%20área%20d>>.
- FADIGAS, E. A. F. A. Energia Solar Fotovoltaica: Fundamentos, Conversão e Viabilidade Técnico-Econômica. In: _____. 1. ed. Brasil: GEPEA, 2017.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>.
- GUERRA, N. et al. Operation and physics of photovoltaic solar cells: An overview. *I+D Tecnológico*, v. 14, n. 2, p. 84–95, 2018.
- INPE. *Atlas Brasileiro de Energia Solar*. 2. ed. Brasil: INPE, 2017.
- International Energy Agency (IEA). *Renewable Electricity Capacity Additions by Technology and Segment, 2016-2028*. 2024. Accessed: 2024-08-03. Disponível em: <<https://www.iea.org/data-and-statistics/charts/renewable-electricity-capacity-additions-by-technology-and-segment-2016-2028>>.

JURAFSKY, D.; MARTIN, J. H. *Transformers and Large Language Models*. [S.l.: s.n.], 2023. Draft de 3 de fevereiro de 2024.

NAVEED, H. et al. A comprehensive overview of large language models. *Preprint submitted to Elsevier*, April 2024. ArXiv:2307.06435v9.

PECULIAR CODING ENDEAVOURS. *Image classification: MLP vs CNN*. 2019. Disponível em: <https://www.peculiar-coding-endeavours.com/2019/mlp_vs_cnn/>.

RABANSER, S.; SHCHUR, O.; GÜNNEMANN, S. Introduction to tensor decompositions and their applications in machine learning. *arXiv preprint arXiv:1711.10781*, 2017.

RANE, N. L.; CHOUDHARY SAURABH P., J. Artificial intelligence and machine learning in renewable and sustainable energy strategies: A critical review and future perspectives. *Partners Universal International Innovation Journal (PUIIJ)*, PU Publications, v. 02, n. 03, p. 80–102, 2024. ISSN 2583-9675. Disponível em: <<https://www.puiij.com>>.

SARKER, I. H. Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, v. 2, n. 420, 2021. Disponível em: <<https://doi.org/10.1007/s42979-021-00815-1>>.

XIAO, W. *Photovoltaic Power System: Modeling, Design, and Control*. [S.l.: s.n.], 2017.

APÊNDICE A – Script de Treinamento de Modelo BERT

O código desenvolvido para o modelo pode ser acessado através do link: [Github](#)

APÊNDICE B – Algoritmo de Dimensionamento da Planta Fotovoltaica

O código desenvolvido para o algoritmo de dimensionamento pode ser acessado através do link: Github

APÊNDICE C – Bases de Dados Utilizadas

Base de Irradiância Solar: Site do Atlas Brasileiro de Energia Solar

Base de Tarifas Energéticas: Portal de Relatórios ANEEL

Base de Inversores e Módulos Fotovoltaicos: Github