

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS

ESCOLA POLITÉCNICA E DE ARTES / ENGENHARIA ELÉTRICA

PROJETO FINAL DE CURSO

PEDRO WILLIE BOMTEMPO CARDOSO

**GESTÃO DE ARMAZENAMENTO DE ENERGIA EM SISTEMAS FOTOVOLTAICOS
HÍBRIDOS COM APRENDIZADO POR REFORÇO**

Projeto Final de Curso como parte dos requisitos para
obtenção do título de bacharel em Engenharia Elétrica
apresentado à Pontifícia Universidade Católica de Goiás.

BANCA EXAMINADORA:

Prof. Me. LUIS FERNANDO PAGOTTI – Orientador. PUC Goiás.

Me. LEVI SANTOS CIDRAL JUNIOR – Co-Orientador. WEG.

Prof. Dr. MARCOS ANTONIO DE SOUSA – PUC Goiás.

Prof. Dr. ANTONIO MARCOS MELO MEDEIROS – PUC Goiás.

Goiânia, 16 de JUNHO de 2026.

Gestão de Armazenamento de Energia em Sistemas Fotovoltaicos Híbridos com Aprendizado por Reforço

PEDRO WILLIE BOMTEMPO CARDOSO

Escola Politécnica e de Artes
Pontifícia Universidade Católica de Goiás
Goiânia, GO, Brasil
20222003800108@pucgoias.edu.br

LUIS FERNANDO PAGOTTI

Escola Politécnica e de Artes
Pontifícia Universidade Católica de Goiás
Goiânia, GO, Brasil
pagotti@pucgoias.edu.br

LEVI SANTOS CIDRAL JUNIOR

WEG
Jaraguá do Sul, SC, Brasil
levi@weg.net

Resumo—O endurecimento do arcabouço regulatório da geração distribuída brasileira, sobretudo a cobrança progressiva da componente Fio B, torna a minimização do uso da rede elétrica cada vez mais vantajosa ao consumidor residencial. Os inversores híbridos comerciais, contudo, operam segundo modos pré-configurados de regras fixas, incapazes de conciliar simultaneamente a redução do consumo da rede e a preservação de reserva de energia para sustentação da carga durante interrupções de fornecimento. Este trabalho propõe um sistema autônomo de gestão de armazenamento baseado em um agente de aprendizado por reforço do tipo *Deep Q-Network*, apoiado por um planejador estatístico, que decide os ciclos de carga e descarga da bateria a partir de dados reais de operação. O sistema foi validado em campo, em uma planta fotovoltaica híbrida residencial real, por meio de um experimento comparativo entre o modo *Backup* convencional e o controle pelo agente. Na janela noturna e de madrugada, a fração da carga atendida pela rede caiu de 80,2% para 28,5%, com a participação da bateria no atendimento dessa demanda elevando-se de praticamente zero para 56,5%. Os resultados demonstram que o agente reduz expressivamente a dependência da rede, preservando a função de reserva, e estabelecem a gestão inteligente do armazenamento como um diferencial viável e replicável no contexto da geração distribuída.

Palavras-chave—Aprendizado por reforço, sistemas fotovoltaicos híbridos, armazenamento de energia, gestão de energia, geração distribuída.

Abstract—The tightening of the Brazilian distributed-generation regulatory framework, particularly the progressive charging of the “Fio B” tariff component, makes minimizing grid usage increasingly advantageous for residential consumers. Commercial hybrid inverters, however, operate under pre-configured fixed-rule modes that cannot simultaneously reconcile the reduction of grid consumption with the preservation of an energy reserve to sustain the load during supply interruptions. This work proposes an autonomous storage-management system based on a *Deep Q-Network* reinforcement learning agent, supported by a statistical planner, that decides the battery charge and discharge cycles from real operational data. The system was validated in the field, on a real residential hybrid photovoltaic plant, through a comparative experiment between the conventional *Backup* mode and control by the agent. During the night and early-morning window, the fraction of the load supplied by the grid dropped from 80.2% to 28.5%, with the battery’s share of meeting that demand rising from nearly zero to 56.5%. The results show that the agent significantly reduces grid dependence while preserving the reserve function, establishing intelligent storage management as a viable and replicable advantage in the distributed-generation context.

Index Terms—Reinforcement learning, hybrid photovoltaic systems, energy storage, energy management, distributed generation.

I. INTRODUÇÃO

A geração distribuída fotovoltaica no Brasil experimentou um dos crescimentos mais expressivos do setor elétrico nacional na última década. Em 2016, a capacidade instalada de sistemas fotovoltaicos residenciais e comerciais era de apenas 93 MW; em 2026, essa marca ultrapassa 68,6 GW em operação, representando uma expansão da ordem de 73.000% em dez anos [1], [2]. Esse salto foi viabilizado por dois fatores principais: o sistema de compensação de energia elétrica instituído pela Resolução Normativa ANEEL n.º 482/2012 e, posteriormente, pelo marco legal da Lei n.º 14.300/2022; e a redução significativa no custo dos equipamentos, com o preço por quilowatt-pico instalado caindo de aproximadamente R\$ 7.500 em 2016 para R\$ 4.500 em 2026 [3]. A Figura 1 ilustra essas duas tendências simultâneas ao longo da última década. Entretanto, o amadurecimento do mercado também trouxe um endurecimento progressivo do arcabouço regulatório.




Figura 1: Capacidade fotovoltaica instalada e custo por quilowatt-pico no Brasil (2016–2026). Fontes: [1]–[3].

Como evidencia a Figura 1, o avanço da capacidade instalada e a redução do custo dos equipamentos ocorreram de forma concomitante: enquanto a potência acumulada cresceu de maneira praticamente exponencial, o preço por quilowatt-pico apresentou trajetória descendente, com um repique pontual em 2022 atribuído a reajustes nos preços internacionais dos módulos. Essa combinação de maior acessibilidade financeira e ganho

de escala explica, em grande medida, a rápida disseminação da geração distribuída no país.

A partir de 2023, com a vigência integral do “Fio B”, a parcela da Tarifa de Uso do Sistema de Distribuição (TUSD) cobrada de geradores distribuídos pelo uso da rede da concessionária, passou a impactar a economia proporcionada pelo modelo tradicional de compensação, reduzindo o percentual de abatimento na fatura mesmo em sistemas devidamente dimensionados [4]. No estado de Goiás, por exemplo, o custo do Fio B atingiu R\$ 0,17 por quilowatt-hora consumido da rede, mesmo quando a unidade consumidora injetou quantidade equivalente de energia [5]. Soma-se a isso a introdução, pela Resolução ANEEL n.º 1.059/2023, da inversão de fluxo como critério formal de reprovação de projetos, bem como a Consulta Pública CP009/2026, que abriu discussão sobre corresponsabilizar a geração distribuída pelo *curtailment* no sistema elétrico nacional [6]. Esse cenário regulatório aponta para uma tendência clara: *minimizar a interação com a rede* torna-se a estratégia financeiramente mais vantajosa para o consumidor residencial.

Nesse contexto, o armazenamento de energia em baterias de íon-lítio emerge como solução técnica para deslocamento de curva de carga, suporte a tarifas horárias, redução de demanda contratada e sustentação durante interrupções no fornecimento. Inversores híbridos comerciais, como os fabricados pela WEG, oferecem quatro modos operacionais pré-configurados, que se distinguem pela ordem de prioridade entre as fontes disponíveis: *Self-Use*, no qual a carga é suprida prioritariamente pela geração solar, em seguida pela bateria e, por último, pela rede; *Feed-in Priority*, no qual o excedente solar é direcionado à injeção na rede até o limite de potência do inversor, sendo a bateria utilizada como fonte secundária para manter essa injeção mesmo sob baixa irradiância; *Peak Shaving*, no qual o inversor limita ativamente a potência drenada da rede a um valor pré-configurado, compensando a diferença a partir da bateria sempre que a carga ultrapassa esse limiar; e *Backup*, no qual o banco permanece em reserva e só é acionado em caso de interrupção do fornecimento.

A limitação evidencia-se quando o objetivo é simultâneo: *maximizar o uso da bateria para*

reduzir o consumo da rede e, ao mesmo tempo, manter reserva suficiente para sustentar a carga durante quedas de energia. Nenhum dos modos pré-configurados atende a essa combinação, e o agendamento estático é inadequado por dois motivos: exige análise individualizada da curva de consumo de cada cliente, o que é operacionalmente inviável em escala; e ignora a variabilidade da carga ao longo do tempo, influenciada por sazonalidade, condições climáticas e mudanças no perfil de consumo. Para abordar essa limitação, este trabalho recorre a técnicas de *Aprendizado por Reforço* (*Reinforcement Learning* – RL), paradigma de aprendizado de máquina no qual um agente aprende políticas eficazes por meio da interação com um ambiente, sem necessidade de regras pré-codificadas para cada cenário [7].

A partir desse paradigma, propõe-se um sistema autônomo de gestão de armazenamento de energia para sistemas fotovoltaicos híbridos residenciais, baseado em uma arquitetura hierárquica de dois agentes. O primeiro agente é um planejador estatístico determinístico que, a partir do histórico de sete dias de operação, identifica o período solar e calcula a janela mais adequada de descarga noturna. O segundo é uma *Deep Q-Network* (DQN), com aproximadamente 10 mil parâmetros treináveis, que decide a cada quinze minutos entre os estados de *Standby* e *Discharge* da bateria. A solução foi implementada em uma planta real composta por inversor híbrido WEG e banco de baterias de 5 kWh, com comunicação local via Modbus RTU através de microcontrolador ESP32 e atuação remota via banco de dados em tempo real hospedado na nuvem. Os resultados apresentados neste artigo correspondem a dados reais de operação, incluindo métricas de economia financeira mensurada em uma instalação residencial em São Luís de Montes Belos – GO.

O restante deste artigo está organizado da seguinte forma. A Seção II apresenta a revisão da literatura sobre sistemas fotovoltaicos híbridos, modos de operação de inversores e fundamentos de aprendizado por reforço aplicados à gestão energética. A Seção III detalha a arquitetura do sistema proposto, incluindo a infraestrutura de comunicação, a formulação do problema como Processo de Decisão de Markov e o projeto dos dois agentes. A Seção IV apresenta e discute os

resultados obtidos em operação real, comparando o desempenho do sistema proposto com os modos tradicionais do inversor. Por fim, a Seção V sintetiza as contribuições do trabalho e indica direções para pesquisas futuras.

II. REVISÃO BIBLIOGRÁFICA

A. Sistemas Fotovoltaicos Híbridos e Armazenamento

Os sistemas fotovoltaicos conectados à rede podem ser classificados, quanto à sua topologia, em três categorias principais. Os sistemas *on-grid* operam exclusivamente em paralelo com a concessionária, sem capacidade de armazenamento, de modo que toda a geração excedente é injetada na rede e o consumo, quando a geração é insuficiente, é integralmente suprido por ela. Os sistemas *off-grid*, por sua vez, operam de forma isolada, dependendo de um banco de baterias dimensionado para garantir autonomia total. Os sistemas híbridos combinam características de ambos: mantêm a conexão com a rede, mas incorporam armazenamento, o que lhes confere a capacidade de deslocar energia no tempo e de sustentar a carga durante interrupções no fornecimento.

A viabilidade dessa última topologia está diretamente associada à tecnologia de armazenamento empregada. As baterias de chumbo-ácido, historicamente predominantes pelo baixo custo inicial, apresentam vida útil reduzida e baixa profundidade de descarga admissível. As baterias de íon-lítio, hoje dominantes em aplicações residenciais, oferecem maior densidade energética, maior número de ciclos e maior profundidade de descarga, ainda que a um custo de aquisição superior. Tecnologias emergentes, como as baterias de fluxo de vanádio, destacam-se pela longevidade em aplicações estacionárias de grande porte, mas permanecem economicamente inviáveis na escala residencial. Independentemente da tecnologia, o banco de baterias constitui o componente de maior custo de uma instalação híbrida, o que torna o aproveitamento eficiente de sua capacidade um fator determinante para o retorno do investimento.

B. Estratégias Clássicas de Gestão de Energia

A operação de um sistema de armazenamento é coordenada por um sistema de gestão de energia (*Energy Management System* – EMS), responsável

por decidir, a cada instante, os fluxos de carga e descarga da bateria. As estratégias clássicas de EMS podem ser agrupadas em duas famílias. A primeira, baseada em regras (*rule-based*), define o comportamento do sistema por meio de condições lógicas predefinidas, por exemplo, carregar a bateria quando há excedente solar e descarregá-la quando o consumo supera a geração. É a abordagem adotada pelos modos operacionais pré-configurados dos inversores comerciais. Sua principal vantagem é a simplicidade de implementação; sua limitação, a rigidez: por não incorporarem previsão nem otimização, as regras fixas não se adaptam à variabilidade da geração e do consumo, conduzindo a decisões subótimas fora das condições para as quais foram concebidas.

A segunda família recorre a técnicas de otimização, com destaque para o controle preditivo baseado em modelo (*Model Predictive Control* – MPC). O MPC formula a operação como um problema de otimização sobre um horizonte futuro, resolvendo-o repetidamente a cada passo de controle e aplicando apenas a primeira ação da trajetória ótima. Trabalhos como o de Raoufat *et al.* [8] demonstram que o MPC supera controladores baseados em regras na redução de custos e no aproveitamento da geração fotovoltaica, além de permitir a incorporação explícita de restrições operacionais e de degradação da bateria. Sua eficácia, contudo, é fortemente dependente da qualidade do modelo do sistema e das previsões de geração e consumo, cuja obtenção é complexa em ambientes residenciais sujeitos a alta incerteza. Essa dependência de um modelo explícito motiva a investigação de abordagens orientadas a dados, capazes de aprender políticas de controle diretamente da operação.

C. Aprendizado por Reforço Aplicado a Sistemas de Energia

O aprendizado por reforço (*Reinforcement Learning* – RL) constitui um paradigma de aprendizado de máquina no qual um agente aprende a tomar decisões por meio da interação com um ambiente [7]. A cada passo, o agente observa um estado, executa uma ação e recebe uma recompensa numérica, ajustando progressivamente sua política, o mapeamento de estados em ações, de modo a maximizar a recompensa acumulada

ao longo do tempo. A formalização matemática desse processo, o Processo de Decisão de Markov, é detalhada na Seção III. A principal vantagem do RL sobre as abordagens clássicas reside em sua natureza orientada a dados: dispensa-se a formulação de um modelo explícito do sistema, uma vez que a política é aprendida diretamente a partir da experiência de operação.

Entre os algoritmos de RL, o *Deep Q-Network* (DQN) destacou-se ao combinar o algoritmo Q-Learning com redes neurais profundas, viabilizando a tomada de decisão em espaços de estados de alta dimensão [9]. Para problemas de ação contínua, algoritmos como o *Deep Deterministic Policy Gradient* (DDPG) foram posteriormente propostos [10]. A aplicação dessas técnicas à gestão de energia tem crescido de forma expressiva. Vázquez-Canteli e Nagy [11] apresentam uma ampla revisão do uso de RL em resposta à demanda, sistematizando algoritmos e técnicas de modelagem. Nakabi e Toivanen [12] aplicaram aprendizado por reforço profundo à gestão de uma microrrede com demanda flexível, ao passo que Hosseini *et al.* [13] propuseram um EMS baseado em RL para o armazenamento em íon-lítio de uma microrrede multinível, comparando-o favoravelmente a estratégias baseadas em lógica fuzzy e em otimização por enxame de partículas. No contexto residencial, Lee e Choi [14] desenvolveram uma estratégia de gestão ótima, baseada em aprendizado profundo, para um sistema doméstico que integra geração fotovoltaica e armazenamento em bateria.

D. Lacunas na Literatura e Posicionamento da Pesquisa

A revisão dos trabalhos correlatos evidencia que o aprendizado por reforço é uma abordagem consolidada e promissora para a gestão de energia. Identificam-se, contudo, lacunas que este trabalho busca preencher. Em primeiro lugar, a maioria dos estudos é validada exclusivamente em ambientes de simulação ou sobre conjuntos de dados públicos, sendo escassos os trabalhos que avaliam o desempenho do agente em uma planta física real, em operação, com dados coletados da própria instalação. Em segundo lugar, grande parte das aplicações tem como objetivo a minimização de custos sob tarifação horária (*time-of-use*), cená-

rio ainda pouco difundido no setor residencial brasileiro; são menos frequentes as formulações voltadas ao contexto específico da geração distribuída nacional, no qual o incentivo financeiro decorre da minimização do uso da rede sob a cobrança progressiva do Fio B. Por fim, observa-se que poucos trabalhos tratam simultaneamente do duplo objetivo de reduzir a dependência da rede e preservar uma reserva de energia para sustentação da carga durante interrupções de fornecimento, requisito central em sistemas híbridos adquiridos com finalidade de *backup*.

É nesse espaço que se posiciona a presente pesquisa: a aplicação de um agente de aprendizado por reforço à gestão do armazenamento de uma planta fotovoltaica híbrida residencial real, com dados reais de operação, sob o arcabouço regulatório brasileiro, e com a preservação explícita da capacidade de reserva como restrição de projeto.

III. METODOLOGIA

A. Visão Geral da Arquitetura

O sistema proposto foi concebido como uma arquitetura distribuída que integra três camadas funcionais: uma camada física, composta pela planta fotovoltaica e pelo hardware de aquisição e atuação; uma camada de comunicação, responsável pela troca de dados em tempo real; e uma camada de decisão, onde reside a inteligência artificial encarregada de definir o modo de operação da bateria. A Figura 2 apresenta o diagrama de blocos do sistema, organizado nessas três camadas e evidenciando o fluxo de informações desde a leitura dos sensores do inversor até o envio do comando de comutação de modo. Nele, as setas bidirecionais indicam fluxos de energia ou de dados que ocorrem em ambos os sentidos.

A decisão sobre o modo de operação da bateria é tomada de forma autônoma a cada intervalo de quinze minutos, com base no estado corrente do sistema. A separação entre a camada de decisão, executada em um servidor remoto, e a camada de atuação, implementada no hardware embarcado junto ao inversor, garante o desacoplamento entre a inteligência e o equipamento físico, permitindo que o inversor mantenha seu último estado conhecido em caso de indisponibilidade do servidor.




Figura 2: Diagrama de blocos do sistema proposto.

B. Sistema Estudado

O objeto de estudo consiste em uma planta fotovoltaica híbrida residencial real, localizada em São Luís de Montes Belos, Goiás. O arranjo gerador é composto por doze módulos fotovoltaicos de 695 Wp cada, totalizando uma potência instalada de 8,34 kWp. A conversão e o gerenciamento de energia são realizados por um inversor híbrido da fabricante WEG, com potência nominal de 5 kW, acoplado a um banco de baterias de íon-lítio com capacidade nominal de armazenamento de 5 kWh e profundidade de descarga útil de 90%, resultando em aproximadamente 4,5 kWh de energia efetivamente disponível por ciclo. O sistema opera conectado à rede de distribuição da concessionária local, caracterizando uma topologia híbrida com possibilidade de injeção de excedente e de uso da bateria como reserva.

A escolha de uma instalação real foi determinante para conferir validade prática ao trabalho, pois forneceu dados autênticos de geração solar, perfil de consumo residencial e estado de carga da bateria, registrados continuamente ao longo da operação. Esses registros históricos constituíram a base empírica para o treinamento do agente. A validação do modelo treinado, por sua vez, foi

conduzida em ambiente de simulação alimentado por esses mesmos dados reais: sobre uma janela de trinta dias de operação, injetaram-se cenários de interrupção no fornecimento, inserindo apagões com duração de três a cinco horas, de modo a avaliar como o agente reagiria diante de diferentes situações de falha sem expor a planta física a riscos. A combinação entre dados reais para treinamento e simulação controlada de apagões para teste permitiu verificar tanto o desempenho do agente quanto sua capacidade de preservar reserva de energia.

C. Infraestrutura de Aquisição e Comunicação

A aquisição de dados e a atuação sobre o inversor são realizadas por um módulo embarcado baseado no microcontrolador ESP32, acoplado a um transceptor RS-485 que implementa a comunicação serial com o inversor por meio do protocolo Modbus RTU. Esse módulo realiza a leitura periódica das grandezas operacionais relevantes, como a potência gerada, a potência consumida pela carga e o estado de carga da bateria, e a escrita de comandos de alteração do modo de operação no registrador correspondente do inversor.

A comunicação entre o módulo embarcado e a camada de decisão é mediada por um banco de dados em tempo real hospedado em nuvem, que atua como ponto central de troca de informações. O microcontrolador publica as leituras coletadas e consulta periodicamente a existência de novos comandos, enquanto o agente de decisão, executado em um servidor virtual dedicado, consome esses dados e publica as decisões correspondentes. Essa arquitetura desacoplada confere robustez ao sistema: eventuais falhas de conectividade ou indisponibilidade do servidor não comprometem a operação local do inversor, que permanece no último modo definido até o recebimento de um novo comando.

D. Formulação do Problema de Decisão

O problema de gestão da bateria foi formulado como um Processo de Decisão de Markov (*Markov Decision Process* — MDP), estrutura matemática adequada à modelagem de decisões sequenciais sob incerteza [7]. Em um MDP, a cada instante de decisão o agente observa o estado corrente do sistema, escolhe uma ação e recebe em

troca uma recompensa numérica, transitando em seguida para um novo estado. O comportamento do agente é descrito por uma política π , que associa a cada estado a ação a ser tomada, e o objetivo do aprendizado é encontrar a política que maximize o retorno esperado, sendo assim, a soma das recompensas obtidas ao longo do tempo, ponderadas por um fator de desconto $\gamma \in [0, 1]$ que atribui menor peso às recompensas mais distantes no futuro:

$$G_t = \sum_{k=0}^{\infty} \gamma^k r_{t+k}, \quad \gamma \in [0, 1], \quad (1)$$

em que G_t é o retorno a partir do instante t e r_{t+k} é a recompensa recebida k passos adiante. Valores de γ próximos de 1 tornam o agente mais providente, propriedade essencial para que ele aprenda a preservar reserva de energia para apagões futuros, em vez de esgotar a bateria de imediato.

Restam definir os espaços de ações e de estados e a função de recompensa. O **espaço de ações** é discreto e binário, $\mathcal{A} = \{\text{STANDBY}, \text{DISCHARGE}\}$: a ação STANDBY mantém a bateria em reserva (modo de *backup*) e a ação DISCHARGE habilita o fornecimento da energia armazenada à carga (modo de *self-use*). O **espaço de estados** é um vetor de doze atributos normalizados que descrevem a condição corrente do sistema — entre eles o estado de carga da bateria, codificações cíclicas do horário, indicadores do período solar, a razão entre energia disponível e déficit noturno estimado, a disponibilidade da rede e a ação tomada no instante anterior.

A **função de recompensa** codifica explicitamente as restrições operacionais do sistema, penalizando comportamentos indesejados e recompensando decisões alinhadas aos objetivos. Destacam-se: a manutenção de reserva mínima para sustentação da carga durante interrupções; a proibição de descarga durante a geração solar; o incentivo à descarga na janela noturna mais adequada; e a penalização de comutações desnecessárias entre modos, preservando a estabilidade do inversor. Essa estratégia, conhecida como *reward shaping*, incorpora o conhecimento prévio do engenheiro sobre o domínio, acelerando a convergência e evitando comportamentos inseguros durante o treinamento.

E. Agente de Decisão: Deep Q-Network

O agente de decisão foi implementado por meio do algoritmo *Deep Q-Network* (DQN), que aproxima a função de valor de ação $Q(s, a)$, o retorno esperado ao se tomar a ação a no estado s , por uma rede neural profunda de parâmetros θ [9]. A escolha do DQN justifica-se pela natureza discreta e binária do espaço de ações, para a qual algoritmos voltados a ações contínuas não oferecem vantagem, e pela simplicidade de inspeção dos valores de Q , que favorece a interpretabilidade das decisões.

A rede neural empregada é um *perceptron* multicamadas (*Multi-Layer Perceptron* — MLP) totalmente conectado, com uma camada de entrada de doze neurônios correspondentes aos atributos do estado, duas camadas ocultas com funções de ativação do tipo *ReLU* e uma camada de saída com dois neurônios, associados aos valores de Q das ações *STANDBY* e *DISCHARGE*. A arquitetura resultante possui aproximadamente 10 mil parâmetros treináveis, dimensionamento deliberadamente compacto que evita sobreajuste, dada a baixa dimensionalidade do problema, e permite treinamento e inferência em tempo reduzido. A Figura 3 ilustra a topologia da rede, na qual, por clareza, apenas alguns neurônios de cada camada são representados.




Figura 3: Arquitetura da rede neural do agente DQN (12–128–64–2).

O treinamento do DQN incorpora os três mecanismos clássicos que conferem estabilidade ao algoritmo: o *experience replay*, que armazena transições em um buffer e amostra mini-lotes aleatórios para quebrar a correlação temporal entre amostras; a *rede-alvo*, cópia defasada da rede principal utilizada no cálculo do alvo de aprendizado; e a política de exploração ϵ -greedy, na qual o agente

seleciona ações aleatórias com probabilidade ϵ decrescente ao longo do treinamento, equilibrando exploração e exploração. Os hiperparâmetros adotados no treinamento estão sintetizados na Tabela I.

Tabela I: Hiperparâmetros do agente DQN

Hiperparâmetro	Valor
Otimizador	Adam
Taxa de aprendizado (η)	5×10^{-4}
Fator de desconto (γ)	0,97
ϵ inicial / final	1,00 / 0,01
Decaimento de ϵ	0,995 por episódio
Capacidade do <i>replay buffer</i>	50.000 transições
Tamanho do mini-lote	64
Atualização da rede-alvo	suave ($\tau = 0,005$)
<i>Clipping</i> de gradiente	norma máxima 1,0
Função de perda	erro quadrático médio

F. Planejador Estatístico de Apoio

Para reduzir a complexidade do problema de aprendizado, o agente neural é apoiado por um planejador estatístico determinístico, que opera sobre o histórico dos sete dias anteriores de operação. Esse módulo, que não emprega aprendizado de máquina, é responsável por extrair regularidades temporais do funcionamento da planta: identifica o início e o término do período de geração solar, estima a carga média no período noturno e calcula a janela temporal mais adequada para a descarga da bateria. As informações produzidas pelo planejador são incorporadas ao vetor de estado do agente, fornecendo contexto temporal que simplifica a tarefa de decisão e mantém as regras de negócio interpretáveis fora da rede neural.

G. Ambiente de Simulação e Treinamento

O treinamento do agente foi realizado de forma *offline*, ou seja, sobre dados históricos já coletados, e não diretamente na planta em operação, estratégia que elimina qualquer risco ao equipamento físico durante a fase de aprendizado. O procedimento adotado pode ser resumido em três etapas encadeadas: a obtenção dos dados reais da planta, a construção de um ambiente de simulação que reproduz a dinâmica do sistema e a injeção de apagões em instantes aleatórios para que o agente aprenda a preservar reserva de energia.

a) *Dados de treinamento:* A base de aprendizado foi extraída do próprio inversor híbrido da planta, na forma de relatórios em tempo real exportados em arquivos CSV, abrangendo trinta dias consecutivos de operação. De cada leitura aproveitaram-se as séries de potência gerada pelos painéis e de potência consumida pela carga, que constituem as variáveis exógenas do ambiente, isto é, o “mundo” que o agente observa, mas não controla. As leituras instantâneas foram agregadas em intervalos regulares de quinze minutos, totalizando noventa e seis *slots* de decisão por dia, e eventuais lacunas foram preenchidas por interpolação linear. Importa destacar que o estado de carga da bateria não é fornecido como dado de entrada do histórico: ele é recalculado a cada passo pela física da bateria, como resultado das decisões do próprio agente, evitando que este tenha acesso a informação que não estaria disponível em operação real.

b) *Construção dos episódios e injeção de apagões:* O aprendizado ocorre por interação do agente com episódios de simulação. A cada episódio, sorteiam-se dois dias consecutivos do histórico de trinta dias, cujas curvas de geração e consumo passam a alimentar o ambiente; o estado de carga inicial da bateria também é sorteado, para diversificar as trajetórias exploradas. O elemento central do método é a injeção estocástica de quedas de energia: em parte dos episódios, simula-se a interrupção do fornecimento da rede durante um intervalo do período noturno, escolhido aleatoriamente, como se a energia da concessionária tivesse de fato faltado naquele momento. Como esses apagões surgem em instantes imprevisíveis ao longo do treinamento, o agente é forçado a aprender, por experiência, a manter uma reserva preventiva de carga, sem depender de qualquer aviso explícito de quando a falha ocorrerá. Essa é a forma pela qual o sistema concilia os dois objetivos conflitantes: economizar energia em condições normais e, ainda assim, dispor de reserva suficiente quando a rede falha.

c) *Laço de aprendizado:* Para cada *slot* de quinze minutos de um episódio, o agente observa o estado, escolhe uma ação segundo a política ϵ -greedy, recebe a recompensa correspondente e armazena a transição no *experience replay*; a rede é então atualizada a partir de um mini-lote

amostrado desse *buffer*, e a rede-alvo é ajustada de forma suave. O processo é repetido ao longo de centenas de episódios, com a probabilidade de exploração ϵ decaindo gradualmente, de modo que o agente parta de um comportamento predominantemente exploratório e convirja para a exploração da política aprendida. Periodicamente, o desempenho do agente é avaliado em cenários determinísticos de teste, com apagões em horários fixos, e apenas o modelo de melhor desempenho, segundo a recompensa acumulada, é preservado, caracterizando uma forma implícita de parada antecipada por *checkpointing*.

As métricas adotadas para essa avaliação incluem a energia retirada da bateria que substituiu o consumo da rede, o estado de carga ao amanhecer, o número de comutações entre modos e a capacidade de sustentação da carga durante interrupções. O procedimento de validação do modelo treinado, conduzido por meio de uma simulação contínua de trinta dias com quedas de energia programadas, e seus resultados quantitativos são detalhados na Seção [IV](#).

IV. RESULTADOS E DISCUSSÕES

A avaliação do sistema proposto foi conduzida diretamente em campo, na planta residencial descrita na Seção [III](#), por meio de um experimento comparativo entre dois regimes de operação. Em uma semana de referência (13 a 19 de abril de 2026), o inversor operou exclusivamente no modo *Backup*, mantendo a bateria em reserva e suprindo toda a carga a partir da rede; em uma segunda semana (10 a 16 de maio de 2026), o sistema operou sob o controle do agente de aprendizado por reforço. Em ambos os períodos, as grandezas de potência da carga, da rede e da bateria foram registradas a cada trinta segundos, e a energia foi obtida por integração temporal dessas leituras. Considerou-se como consumo da rede apenas a parcela efetivamente importada da concessionária, desprezando-se os instantes de exportação de excedente solar.

A. Considerações sobre a Comparação

A análise principal deste trabalho concentra-se na janela das 00h às 09h, período em que a substituição da rede pela bateria é fisicamente possível, conforme detalhado adiante. Nesse intervalo,

as duas semanas apresentaram consumo próximo: 7,08 kWh/dia em média no modo *Backup* contra 5,76 kWh/dia sob o agente. Os valores não são idênticos, mas sua proximidade torna a energia importada da rede confrontável, sobretudo quando expressa como fração da carga. Essa fração, definida como a razão entre a energia importada e a energia total consumida no período, é por isso adotada como métrica principal: por ser normalizada pelo consumo de cada semana, sintetiza em uma única grandeza o efeito da estratégia.

Cabe um esclarecimento sobre essa fração: ela não tende a zero, mesmo sob operação ideal do agente, em razão do limite físico de armazenamento. Os aproximadamente 4,5 kWh de energia útil do banco são insuficientes para cobrir as quase nove horas de consumo do intervalo em todos os dias. A parcela residual atendida pela rede decorre, portanto, da capacidade instalada, e não de uma limitação do algoritmo, que já extrai praticamente toda a energia disponível.




Figura 4: Fração da carga atendida pela rede, por dia (00h–09h).

B. Redução da Dependência da Rede

A Figura 4 apresenta a fração da carga atendida pela rede em cada dia das duas semanas, considerando apenas o período das 00h às 09h. Esse intervalo concentra o consumo noturno e da madrugada, instante em que a bateria, carregada ao longo do dia anterior, pode efetivamente substituir a rede antes que a geração solar assuma o suprimento.

Nesse intervalo, a fração média da carga atendida pela rede caiu de 80,2%, no modo *Backup*,

para 28,5% sob o agente de aprendizado por reforço, uma redução de 64,4% na dependência da rede no período em que essa substituição é fisicamente possível. Considerando o dia completo, a fração caiu de 61,4% para 43,1%. A atenuação do ganho relativo no agregado diário é esperada, pois durante o período de geração solar ambos os regimes exibem baixa importação da rede e, no início da noite, a bateria já se encontra parcialmente descarregada.

C. Perfil Horário de Importação

Para evidenciar o mecanismo por trás dessa redução, a Figura 5 apresenta a potência média importada da rede ao longo das primeiras nove horas do dia, calculada sobre os sete dias de cada regime.




Figura 5: Potência média importada da rede nas primeiras nove horas do dia.

O contraste entre as curvas é o resultado mais ilustrativo do trabalho. No modo *Backup*, a potência importada acompanha a curva de carga durante toda a madrugada, mantendo-se na faixa de 700 a 900 W até que a geração solar assuma o suprimento, por volta das 07h. Sob o controle do agente, a importação despenca para a faixa de poucos watts já a partir da segunda hora do dia e ali permanece, o que demonstra que o agente aprendeu a descarregar a bateria para suprir a carga noturna, em vez de mantê-la ociosa em reserva. O repique observado por volta das 06h sob o agente reflete o momento de transição em que a reserva da noite se esgota e a geração solar ainda é incipiente.

D. Consumo Absoluto e Economia

A Figura 6 apresenta, a título de contexto, a energia total consumida pela carga e a energia

importada da rede, por dia, na semana sob controle do agente. Ainda que os valores absolutos não sejam diretamente comparáveis entre as duas semanas, eles permitem dimensionar a parcela do consumo efetivamente suprida pela rede sob o novo regime de operação.




Figura 6: Carga total e energia importada da rede, por dia (semana sob o agente).

A diferença entre os dois regimes no agregado diário, já apresentada, corresponde à energia que, no modo de reserva, seria importada da concessionária durante a madrugada e que, sob o agente, passou a ser fornecida pela bateria. A Figura 6 permite dimensionar essa parcela em termos absolutos, dia a dia, na semana sob o agente.

E. Implicações Econômicas

Ao longo dos sete dias monitorados, o agente deslocou para a bateria 22,79 kWh de energia que, de outra forma, teriam sido importados da rede no período de madrugada. Projetada para um mês de trinta dias, essa parcela corresponde a aproximadamente 97,7 kWh deslocados. No contexto da geração distribuída, em que o consumidor já não paga a componente plena da tarifa, mas permanece sujeito à cobrança do “Fio B” sobre a energia consumida da rede, essa redução representa uma economia da ordem de R\$ 17,10 mensais. O valor é modesto em termos absolutos, mas equivale a cerca de 16% da parcela de Fio B da fatura na planta analisada, o que evidencia que a estratégia atua precisamente sobre o custo residual que persiste após a instalação do sistema solar.

A relevância da abordagem torna-se mais expressiva quando transposta para consumidores de maior porte. Como a estratégia atua sobre uma fração do consumo, e não sobre um valor fixo, a mesma taxa de aproveitamento observada no estudo de caso se traduz em uma economia absoluta proporcionalmente maior à medida que cresce a demanda da unidade consumidora. Em instalações comerciais de consumo elevado, nas quais a parcela de Fio B representa um custo mensal significativo, esse ganho percentual, ainda que incremental, corresponde a montantes substancialmente mais expressivos do que os verificados na planta residencial analisada. O sistema de gestão inteligente atua, portanto, como um diferencial que agrega valor sobretudo a instalações de maior consumo.

F. Desafios de Implementação

A natureza prática deste trabalho, conduzido sobre uma planta física real, impôs uma série de desafios cuja superação foi parte essencial da contribuição. O primeiro deles foi o acesso ao mapa de registradores Modbus do inversor WEG, informação indispensável tanto para a leitura das grandezas operacionais quanto para a comutação remota do modo de operação; esse acesso só foi viabilizado com o apoio do co-orientador Me. Levi Santos Cidral Junior, diretor de engenharia da WEG.

Um segundo obstáculo, de maior gravidade, foi uma falha de *firmware* do inversor que impedia a alteração do modo de operação para *Backup* via Modbus, justamente a comutação na qual se apoia toda a estratégia de controle. A solução exigiu cerca de duas semanas e o envolvimento do suporte técnico da WEG, com a mediação de Lucas Alves Mota, que estabeleceu a ponte com a fabricante responsável pelo controle e *firmware* do equipamento. A correção resultou em uma atualização lançada em escala global, o que, além de viabilizar a conclusão deste trabalho, eliminou um entrave que poderia afetar outros engenheiros que venham a replicar essa abordagem.

Na etapa de montagem do *hardware* de aquisição, identificou-se ainda um defeito na malha de terra do módulo ESP32 empregado, no qual um dos pontos de *GND* não se encontrava equipotencializado com os demais. Essa falha introduzia in-

terferências intermitentes na leitura do barramento Modbus e demandou um esforço considerável de diagnóstico até que a causa-raiz fosse isolada e corrigida.

Por fim, a necessidade de manter o agente em execução contínua, sem depender de um computador local permanentemente ligado nem do redimensionamento do *hardware* embarcado para executar a inferência localmente, o que encareceria e dificultaria a replicação, motivou a arquitetura distribuída adotada. A combinação de um servidor virtual na nuvem (VPS) com um banco de dados em tempo real e o módulo ESP32+RS-485 para a comunicação com o inversor mostrou-se a solução mais econômica e acessível para esse requisito, e constitui, em si, um dos resultados de engenharia do trabalho.

G. Limitações e Margem de Ganho

Os resultados obtidos devem ser interpretados à luz das condições do estudo. Sob a restrição de capacidade do banco de 5 kWh já discutida, os ganhos verificados são considerados satisfatórios. Há, contudo, margem relevante para ampliá-los. Por um lado, uma maior capacidade de armazenamento permitiria suprir integralmente o consumo noturno, aproximando de zero a dependência da rede nesse período. Por outro, observou-se que o agente operou de forma conservadora, mantendo o estado de carga consistentemente acima do limite físico de 10% da bateria; uma calibração menos rigorosa da função de recompensa quanto à preservação de reserva permitiria explorar uma fração maior da energia armazenada, aumentando o deslocamento de consumo sem comprometer a integridade do banco.

Cabe ainda ressaltar que a avaliação restringiu-se a duas semanas de operação, sob demanda residencial real e variável. Embora isso confira validade prática aos resultados, uma observação de maior duração, abrangendo diferentes estações do ano e um número maior de ocorrências de interrupção no fornecimento, é necessária para consolidar as estimativas de economia e de confiabilidade.

H. Síntese da Discussão

Os resultados confirmam a hipótese central do trabalho: um agente de aprendizado por reforço

é capaz de gerenciar autonomamente o ciclo de carga e descarga da bateria de modo a reduzir significativamente a dependência da rede, sem necessidade de agendamento estático e individualizado da curva de consumo de cada residência. A redução de 64,4% na fração de carga atendida pela rede durante a madrugada demonstra que o agente identificou corretamente a oportunidade de deslocar o consumo noturno para a energia armazenada, comportamento que o modo *Backup*, por construção, jamais exibiria. Mais do que isso, a estratégia reduziu a importação da rede preservando ao mesmo tempo a capacidade de sustentação da carga durante interrupções de fornecimento, objetivo que nenhum dos modos fixos do inversor atende simultaneamente.

A restrição da análise ao período noturno e de madrugada, único em que a substituição da rede pela bateria é possível, e o emprego da fração da carga, métrica normalizada pelo consumo de cada período, mitigam o efeito das diferenças naturais entre as duas semanas e dão sustentação à comparação entre os regimes.

V. CONCLUSÕES

Este trabalho propôs e validou em campo um sistema autônomo de gestão de armazenamento de energia para plantas fotovoltaicas híbridas residenciais, baseado em um agente de aprendizado por reforço do tipo *Deep Q-Network* apoiado por um planejador estatístico. O objetivo central, reduzir a dependência da rede elétrica sem abrir mão da reserva de energia necessária à sustentação da carga durante interrupções de fornecimento, foi alcançado e quantificado a partir de dados reais de operação, coletados em uma instalação em São Luís de Montes Belos, GO.

Convém situar a motivação que orienta toda a abordagem. Embora o custo dos sistemas fotovoltaicos tenha caído expressivamente na última década, os bancos de baterias permanecem o componente mais oneroso de uma instalação híbrida, o que limita, na prática, a capacidade de armazenamento que o consumidor está disposto a adquirir. A planta utilizada neste estudo reflete exatamente essa realidade: trata-se de um sistema já existente, dimensionado com banco de 5 kWh, suficiente para sustentar a carga por aproximadamente seis horas, cuja aquisição teve

como propósito original assegurar tranquilidade ao cliente durante interrupções no fornecimento de energia, e não a maximização da autonomia. Nesse contexto, a contribuição deste trabalho não está em projetar um sistema do zero para a independência da rede, mas em identificar, em um equipamento já comercializado e instalado com outra finalidade, uma oportunidade de agregar valor por meio da gestão inteligente do armazenamento, aplicando o conhecimento técnico e teórico desenvolvido ao longo da formação acadêmica.

O principal resultado experimental demonstra a eficácia da abordagem. Na janela noturna e de madrugada (00h às 09h), período em que a substituição da rede pela bateria é efetivamente possível, a fração da carga atendida pela rede caiu de 80,2%, no modo *Backup* convencional, para 28,5% sob o controle do agente, uma redução de 51,7 pontos percentuais, equivalente a 64,4% em termos relativos. Em outras palavras, mais da metade do consumo que antes era integralmente importado da concessionária passou a ser suprido pela energia armazenada: a participação da bateria no atendimento da carga desse período saltou de praticamente zero (0,1%) para 56,5%. Esse é um comportamento que nenhum dos modos pré-configurados do inversor seria capaz de exibir, uma vez que o modo *Backup* mantém a bateria ociosa em reserva e os demais modos não preservam a capacidade de sustentação durante apagões. As implicações econômicas dessa redução, os desafios de implementação enfrentados e as limitações do estudo foram analisados na Seção [IV](#).

A. Trabalhos Futuros

Como desdobramentos desta pesquisa, identificam-se as seguintes direções: o dimensionamento conjunto do banco de baterias e da política de controle, de modo a maximizar o aproveitamento da energia armazenada; o aumento da robustez do sistema mediante maior disponibilidade de investimento, que permitiria estender o período de treinamento do agente e ampliar a janela de observação experimental, conduzindo a estimativas mais precisas de economia e confiabilidade ao longo de diferentes estações do ano; a incorporação de previsão de geração solar ao vetor de estado do agente, complementando a caracterização do perfil de

carga que o planejador já constrói e refina progressivamente a cada ciclo de operação; a inclusão explícita de um modelo de degradação da bateria na função de recompensa, equilibrando economia e vida útil do banco; e a extensão do sistema a instalações comerciais de maior porte, onde, como indicado pela análise econômica, o impacto financeiro absoluto da estratégia é significativamente maior.

Em síntese, este trabalho demonstrou que um agente de aprendizado por reforço, treinado e validado sobre dados reais, é capaz de gerenciar autonomamente o armazenamento de energia de forma a reduzir expressivamente a dependência da rede, preservando simultaneamente a função de reserva do sistema. Mais do que um ganho econômico imediato, incremental, porém real, a contribuição central reside em estabelecer a gestão inteligente do armazenamento como um diferencial viável e replicável no contexto da geração distribuída brasileira, particularmente diante do endurecimento regulatório que torna a minimização do uso da rede cada vez mais vantajosa.

APÊNDICE

Este anexo reúne o registro fotográfico do sistema em operação na residência monitorada em São Luís de Montes Belos, GO. A Figura [7](#) apresenta a vista geral da planta, com o inversor híbrido WEG, o banco de baterias e o quadro de aquisição, e a Figura [8](#) detalha o módulo embarcado de aquisição e atuação, baseado no microcontrolador ESP32 com transceptor RS-485, responsável pela comunicação Modbus RTU com o inversor.



Figura 7: Vista geral da instalação física.




Figura 8: Módulo embarcado de aquisição (ESP32 com RS-485).

REFERÊNCIAS

- [1] ABSOLAR, “Energia solar fotovoltaica no brasil: Infográfico absolar,” Associação Brasileira de Energia Solar Fotovoltaica, 2026, disponível em: <https://www.absolar.org.br>. Acesso em: [data].
- [2] Agência Brasil, “Capacidade instalada de geração distribuída fotovoltaica no brasil,” 2026, disponível em: <https://agenciabrasil.ebc.com.br>. Acesso em: [data].
- [3] Greener, “Estudo estratégico: Geração distribuída – mercado fotovoltaico,” Relatório de mercado, 2025, disponível em: <https://www.greener.com.br>. Acesso em: [data].
- [4] ANEEL, “Resolução normativa n.º 1.000, de 7 de dezembro de 2021,” Agência Nacional de Energia Elétrica, 2021, disponível em: <https://www.aneel.gov.br>. Acesso em: [data].
- [5] Equatorial Goiás, “Nota técnica 0316/2026: Análise de geração distribuída – atendimento ao cliente/acessante,” Gerência de Planejamento da Expansão / Executiva de Geração Distribuída, Goiânia, GO, Mar. 2026, nota SAP/CRM/SS n.º 1255001.
- [6] ANEEL, “Consulta pública cp009/2026 – correspondência da geração distribuída pelo *curtailment* no sistema elétrico nacional,” Agência Nacional de Energia Elétrica, 2026, disponível em: <https://www.aneel.gov.br>. Acesso em: [data].
- [7] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed. Cambridge, MA: MIT Press, 2018.
- [8] M. E. Raoufat, B. Asghari, and R. Sharma, “Model predictive BESS control for demand charge management and PV-utilization improvement,” *arXiv preprint arXiv:1712.06787*, 2017.
- [9] V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. Riedmiller, A. K. Fidjeland, G. Ostrovski *et al.*, “Human-level control through deep reinforcement learning,” *Nature*, vol. 518, no. 7540, pp. 529–533, 2015.
- [10] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver, and D. Wierstra, “Continuous control with deep reinforcement learning,” in *International Conference on Learning Representations (ICLR)*, 2016.
- [11] J. R. Vázquez-Canteli and Z. Nagy, “Reinforcement learning for demand response: A review of algorithms and modeling techniques,” *Applied Energy*, vol. 235, pp. 1072–1089, 2019.
- [12] T. A. Nakabi and P. Toivanen, “Deep reinforcement learning for energy management in a microgrid with flexible demand,” *Sustainable Energy, Grids and Networks*, vol. 25, p. 100413, 2021.
- [13] E. Hosseini, P. Horrillo-Quintero, D. Carrasco-González, P. García-Triviño, R. Sarrias-Mena, C. A. García-Vázquez, and L. M. Fernández-Ramírez, “Reinforcement learning-based energy management system for lithium-ion battery storage in a multilevel microgrid,” *Journal of Energy Storage*, vol. 105, p. 114674, 2025.
- [14] S. Lee and D.-H. Choi, “Deep learning based optimal energy management for photovoltaic and battery energy storage integrated home micro-grid system,” *Scientific Reports*, vol. 12, p. 15054, 2022.

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante **Pedro Willie Bomtempo Cardoso** do Curso de **Engenharia Elétrica** matrícula **2022.2.0038.0010-8**, telefone: **(64) 99287-4221** e-mail **willie.engenharia@gmail.com**, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado ***Gestão de Armazenamento de Energia em Sistemas Fotovoltaicos Híbridos com Aprendizado por Reforço***, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, **30 de março de 2026**.

Documento assinado digitalmente
gov.br PEDRO WILLIE BOMTEMPO CARDOSO
Data: 30/03/2026 09:09:44-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do autor: _____

Nome completo do autor: **Pedro Willie Bomtempo Cardoso**

Documento assinado digitalmente
gov.br LUIS FERNANDO PAGOTTI
Data: 01/04/2026 09:40:33-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do professor-orientador: _____

Nome completo do professor-orientador: **Luis Fernando Pagotti**