



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIAS RENOVÁVEIS



LUCAS HAAS

**Otimização e Integração de um Sistema de
Armazenamento de Energia em Baterias e
Câmera de Céu em uma Usina Fotovoltaica**

JOÃO PESSOA - PB
2024

PPGER / MESTRADO ACADÊMICO / N° 116

LUCAS HAAS

**OTIMIZAÇÃO E INTEGRAÇÃO DE UM SISTEMA DE ARMAZENAMENTO DE
ENERGIA EM BATERIAS E CÂMERA DE CÉU EM UMA USINA FOTOVOLTAICA**

Dissertação apresentada à Universidade Federal da Paraíba, como parte das exigências do Programa de Pós-Graduação em Energias Renováveis do Centro de Energias Alternativas e Renováveis, área de concentração em energias renováveis, para a obtenção do título de Mestre.

Orientador

Dr. Italo Roger Ferreira Moreno Pinheiro Da Silva

**JOÃO PESSOA - PB
2024**

Catálogo na publicação
Seção de Catalogação e Classificação

H112o Haas, Lucas.

Otimização e integração de um sistema de armazenamento de energia em baterias e câmera de céu em uma usina fotovoltaica / Lucas Haas. - João Pessoa, 2024.

139 f. : il.

Orientação: Italo Roger Ferreira Moreno Pinheiro Silva.

Coorientação: Lucas Vinicius Hartmann.

Dissertação (Mestrado) - UFPB/CEAR.

1. Energias renováveis. 2. Usinas fotovoltaicas. 3. Energia em baterias - Armazenamento. 4. Câmera de céu. I. Silva, Italo Roger Ferreira Moreno Pinheiro. II. Hartmann, Lucas Vinicius. III. Título.

UFPB/BC

CDU 620.91(043)

Programa de Pós-graduação em Energias Renováveis – PPGER

Otimização e Integração de um Sistema de Armazenamento de Energia em Baterias e Câmera de Céu em uma usina Fotovoltaica

por


Lucas Haas

Dissertação aprovada em 25 de Julho de 2024.

Documento assinado digitalmente
 **ITALO ROGER FERREIRA MORENO PINHEIRO DA**
Data: 19/08/2024 08:48:19-0300
Verifique em <https://validar.it.gov.br>


Orientador - UFPB

Dr. Italo Roger Ferreira Moreno Pinheiro Da
Silva



Coorientador - UFPB

Dr. Lucas Vinicius Haartman



Examinadora Interna - UFPB

Dra. Monica Carvalho

Documento assinado digitalmente
 **NADY ROCHA**
Data: 17/08/2024 10:32:31-0300
Verifique em <https://validar.it.gov.br>

Examinador Externo - UFPB

Dr. Nady Rocha

João Pessoa - PB

Julho, 2024

Resumo

A inserção de novos equipamentos em usinas fotovoltaicas (*photovoltaic* - PVs), como o sistema de armazenamento de energia em baterias (*battery energy storage system* - BESS) e a câmera de céu (*all-sky camera* - ASC), traz melhorias e novos desafios, abordados neste trabalho. O BESS transforma a usina PV em uma fonte de energia despachável e a ASC possibilita a previsão de eventos de sombreamento. Neste estudo, a integração desses equipamentos em usinas PV foi analisada em três frentes. Primeiramente, foram desenvolvidos dois sistemas de comunicação escaláveis e de código aberto para coletar dados do sistema PV/BESS com ASC. Os requisitos de coleta de dados foram estabelecidos com base nos sistemas que controlam a usina e na norma IEC-61724. Em seguida, a projeção da potência do BESS foi otimizada para maximizar o lucro da venda de energia. Métodos exato (programação não linear) e heurístico (algoritmo genético) foram aplicados e comparados, com o método exato proporcionando um ganho médio de 6,94% na rentabilidade da usina PV ao longo de 363 dias. Por fim, foi desenvolvido um método de previsão de irradiância de curtíssimo prazo, baseado em fotos da ASC e utilizando uma rede neural híbrida *Convolutional Neural Network - Long Short Term Memory* (CNN-LSTM). O modelo apresenta um erro médio absoluto de 46,751 W/m², e é apresentado um exemplo da aplicação dessa previsão na suavização da potência fornecida à rede elétrica. Deste modo, a integração do BESS e ASC em usinas PV demonstrou reduzir as variações abruptas na geração de energia, contribuindo para a estabilidade da rede elétrica e permitindo uma maior participação da energia solar na matriz energética.

Palavras-chave: intermitência, armazenamento, previsão, projeção, comunicação.

Abstract

The integration of new equipment in photovoltaic (PV) power plants, such as the battery energy storage system (BESS) and the all-sky camera (ASC), brings improvements and challenges, which are addressed in this work. The BESS transforms the PV plant into a dispatchable energy source, and the ASC enables the forecasting of shading events. In this study, the integration of these devices in PV plants was analyzed on three fronts. First, two scalable and open-source communication systems were developed to collect data from the PV/BESS system with ASC. The data collection requirements were established based on the systems that control the plant and the IEC-61724 standard. Subsequently, the power projection of the BESS was optimized to maximize the profit from energy sales. An exact method (nonlinear programming) and a heuristic method (genetic algorithm) were applied and compared, with the exact method providing an average gain of 6.94% in the profitability of the PV plant over 363 days. Finally, a very short-term irradiance forecasting method was developed, based on photos from the ASC and utilizing a hybrid neural network called Convolutional Neural Network - Long Short Term Memory (CNN-LSTM). The model presents a mean absolute error of 46.751 W/m², and an example of the application of this forecast in smoothing the power supplied to the electrical grid is provided. Thus, the integration of the BESS and ASC in PV plants has demonstrated a reduction in abrupt variations in energy generation, contributing to the stability of the electrical grid and allowing for a greater participation of solar energy in the energy matrix.

Keywords: intermittency, storage, forecasting, projection, communication.

Lista de Ilustrações

Figura 1 – <i>Peak shaving</i>	28
Figura 2 – <i>Time shifting</i>	29
Figura 3 – Queda abrupta causada pelo sombreamento.	29
Figura 4 – Conexões elétricas e de dados entre os equipamentos.	33
Figura 5 – Principais equipamentos do setup experimental PV/BESS, que incluem o (a) inversor, medidor de energia, BESS, (b) ASC, módulos PV, (c) SCADA das fotos da câmera e (d) estação meteorológica.	34
Figura 6 – Frame do Modbus RTU e do Modbus TCP.	37
Figura 7 – Arquitetura de comunicação do sistema PV/BESS.	42
Figura 8 – Comparação entre amostragens do mesmo GHI	43
Figura 9 – (a) GHI , (b) foto da ASC e (c) direção e velocidade do vento.	45
Figura 10 – (a) GHI , (b) foto da ASC e (c) direção e velocidade do vento.	45
Figura 11 – (a) GHI , (b) foto da ASC e (c) direção e velocidade do vento.	46
Figura 12 – Perfil do PLD do submercado Nordeste ao longo dos últimos anos.	62
Figura 13 – Variação do PLD do submercado Nordeste ao longo do dia 18 de novembro de 2023.	63
Figura 14 – Comparação entre o 1400 amostras do $P_{PV,REAL}$ e $P_{PV,CALC}$	65
Figura 15 – Comparação entre o P_{PV} e o P_{PV} com erro imbutido, amostrados em 60 min, de forma a simular a previsão de $P_{PV,fut}$	66
Figura 16 – Comparação entre o P_{PV} e o P_{PV} com erro imbutido, amostrados em 10 min, de forma a simular a previsão de $P_{PV,fut}$	67
Figura 17 – Balanço de potência realizado ao redor do inversor.	73
Figura 18 – Balanço de energia realizado ao redor do BESS.	74
Figura 19 – Relação entre L_{MR} , L_{MCP} e L_{TOTAL} para os 363 dias analisados.	77
Figura 20 – Valor do L_{TOTAL} otimizado por um MH em função do tempo de execução, em comparação com o L_{TOTAL} otimizado por um MX, para o dia 18 de novembro de 2023.	78
Figura 21 – Distribuição da diferença entre o L_{TOTAL} calculado por um MH e por um MX.	79
Figura 22 – Projeção de $P_{BESS,fut}$ feita com $p = 60$ min.	80
Figura 23 – Projeção de $P_{BESS,fut}$ feita com $p = 10$ min.	81
Figura 24 – Projeção de $P_{BESS,fut}$ suavizada, a partir da inserção de C_{SUAV} na otimização.	82
Figura 25 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 00h00 do mesmo dia.	83

Figura 26 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 05h00 do mesmo dia.	83
Figura 27 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 08h40 do mesmo dia.	84
Figura 28 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 16h40 do mesmo dia.	85
Figura 29 – Impacto da incerteza da previsão de GHI na projeção de L_{TOTAL} ao longo do dia 18 de novembro de 2023.	85
Figura 30 – Distância entre o resultado considerando previsão sem erro e o resultado considerando previsão realística.	86
Figura 31 – Comparação entre L_{TOTAL} otimizado da usina PV/BESS e o L_{TOTAL} de uma usina PV sem BESS.	87
Figura 32 – Comparação entre L_{TOTAL} calculado por uma usina PV com BESS otimizado e uma usina PV sem BESS.	87
Figura 33 – Parâmetros medidos utilizados como entrada do modelo de previsão, ao longo do dia 18 de dezembro de 2022.	100
Figura 34 – Comparação entre GHI medido e o GHI_{CLEAR} estimado para o dia 18 de dezembro de 2022.	102
Figura 35 – Variação de ΔGHI_{CLEAR} ao longo do dia 18 de dezembro de 2022.	102
Figura 36 – Exemplos de fotos da ASC.	104
Figura 37 – Sequência de zooms aplicados a uma foto da ASC	105
Figura 38 – Ilustração da Camada LSTM da rede neural LSTM.	106
Figura 39 – Função σ	107
Figura 40 – Função $\tanh$	108
Figura 41 – Camadas densas ligadas entre si e aos blocos de entrada e saída.	109
Figura 42 – Camadas da rede CNN.	110
Figura 43 – Filtro sendo aplicado à fatia da foto apresentada na Fig. 37.	111
Figura 44 – Camada <i>pooling</i>	112
Figura 45 – Função ReLU	112
Figura 46 – Arquitetura da rede neural do modelo de previsão de GHI	117
Figura 47 – Comparação entre GHI_{REAL} e GHI_{PREV} de 40.000 amostras de teste.	119
Figura 48 – Comparação entre GHI_{REAL} e GHI_{PREV} de 1.000 amostras de teste.	119
Figura 49 – Distribuição do Erro da previsão de GHI_{PREV}	121
Figura 50 – Erro por GHI_{REAL}	122
Figura 51 – Comparação entre $P_{G,BRUTO}$ e $P_{G,SUAV}$, entre 06h00m e 10h00m do dia 24 de julho de 2023.	123
Figura 52 – Comparação entre $P_{G,BRUTO}$ e $P_{G,SUAV}$, entre 08h07m20s e 08h10m00s do dia 24 de julho de 2023.	124

Figura 53 – Comparação entre $P_{G,BRUTO}$ e $P_{G,PREV}$, entre 08h07m00s e 08h35m00s
do dia 24 de julho de 2023. 125

Lista de Tabelas

Tabela 1 – Parâmetros medidos em usinas PV descritos na norma IEC 61724-1 (ANSI, 2021).	30
Tabela 2 – Características do SE Preditor de Geração de Energia.	36
Tabela 3 – Características do SE Preditor de Queda de Geração de Energia.	36
Tabela 4 – Características do SE EMS.	36
Tabela 5 – Descrição do cabeçalho do Modbus TCP.	38
Tabela 6 – Tipos de dados transmitidos.	38
Tabela 7 – Exemplos de registros dos equipamentos Inversor Sun2000, BESS Luna2000 e Smart Power Sensor DDSU666-H.	39
Tabela 8 – Comparação estatística de diferentes amostragens do mesmo <i>GHI</i>	43
Tabela 9 – Quantidade de MHs e MXs utilizados na otimização de BESS, na evisão feita por Osorio (2023).	54
Tabela 10 – Comparação entre MHs e MXs.	60
Tabela 11 – Parâmetros do módulo PV JINKO JKM530M-72HL4-TV, utilizado na usina experimental PV/BESS.	64
Tabela 12 – Variáveis de decisão e seus limites.	69
Tabela 13 – Parâmetros fixos de entrada.	70
Tabela 14 – Parâmetros variáveis de entrada.	71
Tabela 15 – Valor otimizado pelo MX em comparação com os valores otimizados pelo MH em diferentes iterações.	79
Tabela 16 – Classificação da previsão de energia solar baseada na amostragem e horizonte.	95
Tabela 17 – Variáveis de decisão e seus limites.	115
Tabela 18 – Parâmetros fixos de entrada.	116
Tabela 19 – Parâmetros variáveis de entrada.	116
Tabela 20 – Métricas de desempenho do modelo de previsão de <i>GHI</i> para os erros e os erros absolutos.	120
Tabela 21 – Principais Faixas do Histograma da Fig. 49.	122

Lista de Siglas

ANEEL Agência Nacional de Energia Elétrica. 57

CCEE Câmara de Comercialização de Energia Elétrica. 57, 72

ONS Operador Nacional do Sistema Elétrico. 21, 23

SIN Sistema Interligado Nacional. 18, 23, 32, 33, 36, 57, 61, 72

Lista de Abreviaturas

ACR Ambiente de contratação regulada. 56

ADU Unidade de dados da aplicação, do inglês *application data unit*. 37, 38

ASC Câmera de céu, do inglês *all-sky camera*. 5, 6, 7, 8, 12, 17, 20, 21, 24, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 93, 94, 96, 97, 98, 99, 100, 101, 103, 104, 105, 110, 111, 113, 117, 118, 123, 125, 126, 131

ASI Foto da ASC, do inglês *all-sky image*. 117, 118

BESS Sistema de armazenamento de energia em baterias, do inglês *battery energy storage system*. 5, 6, 7, 8, 10, 13, 14, 15, 16, 17, 20, 21, 22, 23, 24, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 39, 42, 46, 47, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 93, 94, 95, 98, 99, 114, 115, 116, 126, 131

CNN Rede neural convolucional, do inglês *convolutional neural network*. 12, 93, 94, 96, 97, 99, 105, 110, 113, 117, 118

CNN-LSTM Rede neural híbrida CNN-LSTM. 5, 6, 19, 93, 94, 96, 97, 105, 113, 117

EMS Sistema de gerenciamento de energia, do inglês *energy management system*. 10, 35, 36, 41, 42, 81, 124

ESS Sistema de armazenamento de Energia, do inglês *energy storage system*. 53

FG Porta de esquecimento do bloco LSTM, do inglês *forget gate*. 107, 108

GA Algoritmo Genético, do inglês *genetic algorithm*. 53, 54, 57, 58, 59, 60, 78

IG Porta de entrada do bloco LSTM, do inglês *input gate*. 107, 108

LSTM Rede neural de memória de longo curto prazo, do inglês *long short term memory*. 8, 12, 13, 19, 93, 94, 96, 99, 105, 106, 107, 108, 109, 110, 113, 118, 126

MCP Mercado de curto prazo. 56, 61, 77, 88

MH Método Heurístico de Otimização. 7, 10, 18, 53, 54, 55, 56, 57, 58, 59, 60, 67, 76, 77, 78, 79, 80, 88, 89

MX Método Exato de Otimização. 7, 10, 18, 54, 55, 56, 57, 58, 59, 60, 61, 67, 72, 76, 77, 78, 79, 80, 88

OG Porta de saída do bloco LSTM, do inglês *output gate*. 107, 108

PDU Unidade de dados de protocolo, do inglês *protocol data unit*. 37, 38

PLC Comunicação por linha de potência, do inglês *power line communication*. 31

PSO Otimização por enxame de partículas, do inglês *particle swarm optimization*. 53, 54, 60

PV Fotovoltaico. 5, 6, 7, 8, 10, 13, 15, 16, 20, 21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 42, 43, 45, 46, 47, 51, 52, 53, 54, 56, 57, 61, 63, 64, 65, 68, 69, 71, 72, 73, 76, 86, 87, 88, 89, 93, 94, 97, 98, 99, 100, 115, 126, 131

PV/BESS PV com BESS acoplado. 5, 6, 7, 8, 10, 14, 17, 24, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 53, 55, 56, 57, 64, 65, 68, 69, 86, 87, 88, 89, 101, 114, 115, 116, 122, 123, 125, 126, 131

SC Sistema de comunicação. 17, 24, 26, 27, 29, 31, 32, 35, 36, 37, 40, 41, 42, 43, 45, 46, 47, 57, 63, 96, 100, 131

SCADA Aquisição de Dados e Controle de Supervisório, do inglês *supervisory control and data acquisition*. 7, 31, 34

SE Sistema especialista. 10, 35, 36, 40, 41, 42

VD Variável de decisão. 67, 68, 69, 70, 72, 114, 115

Lista de Símbolos

- ΔGHI_{CLEAR} Variação da irradiância global horizontal de céu aberto. 8, 102, 103, 106, 109, 113, 118
- $\Delta P_G/min$ Variação por minuto da potência fornecida à rede elétrica. 22, 23, 98, 115, 123, 124, 125
- η_{GRID} Eficiência de transmissão de P_G da usina PV/BESS à rede elétrica.. 70, 73, 80, 116
- η_{carga} Eficiência do BESS de carga. 70, 71, 73, 80, 116
- $\eta_{descarga}$ Eficiência do BESS de descarga. 70, 71, 73, 80, 116
- $\eta_{inversão}$ Eficiência do inversor fotovoltaico. 70, 73, 80, 116
- C_{BESS} Custo de aquisição do BESS, em R\$.. 70, 71, 74
- C_{CA} Custo de *Calendar Aging*, em R\$.. 68, 69, 75, 78, 88, 89
- C_{DOD} Custo do *DOD*, em R\$.. 68, 69, 74, 78, 88, 89
- C_{SUAV} Custo de suavização, em R\$. 7, 18, 68, 69, 75, 76, 78, 80, 81, 82, 88, 89
- DHI Irradiância difusa horizontal, do inglês *diffuse horizontal irradiance*, em W/m². 30, 35, 93, 94, 100, 101, 103, 106, 109, 113, 118
- DNI Irradiância direta normal, do inglês *direct normal irradiance*, em W/m². 30, 35, 101
- DOD Profundidade de descarga, do inglês *depth of discharge*, em kWh.. 14, 69, 115
- DOD_{AVG} *DOD* médio, em kWh. 69, 74
- EOF Capacidade do BESS no fim de vida, do inglês *End of Life*.. 70, 71, 75
- E_{CONT} Energia contratada, em kWh.. 61, 70, 71, 76, 77, 89
- E_T Energia total utilizável durante a vida útil do BESS, em kWh.. 69, 70, 74
- E_m Energia medida, em kWh. 61, 69, 114, 115
- E_t Energia usada durante o ciclo atual, em kWh.. 69, 74, 75
- $F_{OBJETIVO}$ Função objetivo, em R\$. 67, 68

GHI Irradiância global horizontal, do inglês *global horizontal irradiance*, em W/m². 7, 8, 10, 15, 30, 32, 35, 43, 44, 45, 46, 47, 63, 81, 85, 93, 94, 95, 96, 97, 98, 99, 100, 101, 102, 103, 105, 106, 109, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122, 123, 125, 126, 131

GHI_{CLEAR} Irradiância global horizontal de céu aberto, em W/m². 8, 101, 102, 103

GHI_{PREV} GHI previsto, em W/m². 8, 113, 114, 117, 118, 119, 121, 123

GHI_{REAL} GHI medido, em W/m². 8, 113, 114, 117, 118, 119, 122, 123

L_{MCP} Lucro obtido a partir da venda de energia no Mercado de Curto Prazo, em R\$.. 7, 18, 61, 71, 76, 77

L_{MR} Lucro obtido a partir da venda de energia no Mercado Regulado, em R\$.. 7, 18, 61, 71, 76, 77

L_{TOTAL} Lucro total, em R\$.. 7, 8, 18, 61, 68, 69, 74, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89

Lft Tempo de vida do BESS, em meses. 75

N Quantidade de meses de vida útil.. 74

PLD Preço Líquido das Diferenças, em R\$/kWh.. 7, 61, 62, 63, 71, 72, 76, 80, 81, 88

POA Irradiância no plano do arranjo, do inglês *plane of array irradiance*, em W/m². 30

P_{lim} Potência limite do inversor, em kW. 70, 80, 87, 88

P_{BESS} Potência do BESS, em kW. 7, 18, 56, 57, 58, 59, 68, 69, 71, 72, 73, 76, 78, 80, 81, 82, 84, 86, 89, 115

P_G Potência fornecida à rede elétrica, em kW. 14, 15, 18, 29, 68, 69, 70, 73, 75, 76, 81, 82, 93, 94, 99, 114, 115, 116, 117, 123, 124, 125, 126

$P_{G,BRUTO}$ P_G antes de ser suavizada, em kW. 8, 9, 114, 115, 116, 123, 124, 125

$P_{G,PREV}$ P_G prevista, em kW. 9, 123, 124, 125

$P_{G,SUAV}$ P_G suavizada, em kW. 8, 114, 115, 123, 124, 125

P_{PV} Potência dos módulos PVs. 7, 18, 29, 63, 64, 65, 66, 67, 71, 72, 73, 76, 80, 81, 82, 83, 84, 86, 87, 88, 89, 95, 96, 98, 99, 114, 115

Q Capacidade de armazenamento do BESS, em kWh. 70, 89, 116

R Coeficiente de ROSS. 64

SOC Estado de carga, do inglês *state of charge*. 16, 59, 69, 70, 73, 75, 98, 115, 116

SOC_{-1} SOC do estado anterior, em kWh. 70

SOC_0 SOC do estado inicial, em kWh. 70, 80, 116

T intervalo da otimização, em min ou h. 68, 69, 70, 74, 115

T_{BESS} Temperatura média do BESS, em °C. 71, 72, 75

T_{CEL} Temperatura média das células PVs. 64

V_{CONT} Valor da energia contratada, em R\$/kWh. 61, 70, 71, 77, 89

hrz Horizonte de previsão, em min ou h. 95, 96, 97, 98, 99

p período da amostra, em min. 7, 74, 76, 80, 81, 82, 83, 84, 86, 95, 96, 97, 98

t amostra. 68, 69, 71, 74, 75, 81, 83, 113, 115, 116, 123

Sumário

1	INTRODUÇÃO GERAL	20
1.1	Contextualização	22
1.2	Justificativa	23
1.3	Objetivos	23
1.4	Organização do Documento	24
1.5	Limitações	25
1.6	Agradecimentos	25
2	DESENVOLVIMENTO DE SISTEMAS DE COMU- NICAÇÃO DE UMA USINA PV/BESS COM ASC .	26
2.1	Introdução	28
2.1.1	Revisão da Literatura	29
2.1.2	Objetivo Geral	31
2.1.3	Objetivos Específicos	31
2.1.4	Contribuições	32
2.2	Metodologia	32
2.2.1	Equipamentos da planta PV/BESS com ASC	33
2.2.2	Requisitos de dados em usinas PV/BESS.	35
2.2.3	SC em Modbus	37
2.2.4	SC da ASC	40
2.2.5	Arquitetura de Comunicação	41
2.3	Resultados e Discussão	42
2.4	Conclusão	46
3	OTIMIZAÇÃO DA PROJEÇÃO DA POTÊNCIA DE UM BESS	51
3.1	Introdução	53
3.1.1	Revisão da Literatura	53
3.1.2	Objetivo Geral	56
3.1.3	Objetivos Específicos	56
3.1.4	Contribuições	56
3.1.5	Delimitações do Trabalho	57
3.2	Metodologia	57
3.2.1	Algoritmos de otimização	57
3.2.1.1	Método Heurístico	58
3.2.1.2	Método Exato	59

3.2.1.3	Comparação das características dos MHs e MXs.	59
3.2.2	Precificação de energia do SIN	61
3.2.3	Simulação e Previsão de P_{PV}	63
3.2.3.1	Simulação de P_{PV}	64
3.2.3.2	Simulação da Previsão de P_{PV}	65
3.2.4	Estrutura do script de otimização	67
3.2.4.1	Função Objetivo	67
3.2.4.2	Variáveis de Decisão	68
3.2.4.3	Parâmetros de Entrada	70
3.2.4.4	Restrições	72
3.2.4.4.1	Balço de Potência	73
3.2.4.4.2	Cálculo do SOC	73
3.2.4.4.3	Custos de degradação devido ao uso	74
3.2.4.4.4	Custos de degradação devido ao não uso	75
3.2.4.4.5	Custo de suavização de P_G	75
3.3	Resultados e Discussão	76
3.3.1	Relação entre L_{MR} , L_{MCP} e L_{TOTAL}	76
3.3.2	Comparação entre o resultado da otimização utilizando MH e MX . . .	77
3.3.3	Impacto da amostragem no resultado da otimização	80
3.3.4	Impacto do custo C_{SUAV} na curva de P_G	81
3.3.5	Impacto da incerteza da previsão de $P_{PV,fut}$ na projeção de $P_{BESS,fut}$ e L_{TOTAL} ao longo de um dia.	82
3.3.6	Comparação entre L_{TOTAL} com BESS otimizado e sem BESS	86
3.4	Conclusão	88

4 PREVISÃO DE IRRADIÂNCIA BASEADA EM FOTOS DO CÉU PARA SUAVIZAR A POTÊNCIA FOTOGERADA 93

4.1	Introdução	95
4.1.1	Revisão da Literatura	96
4.1.2	Objetivo Geral	99
4.1.3	Objetivos Específicos	99
4.2	Metodologia	99
4.2.1	Parâmetros de entrada do modelo	100
4.2.1.1	Parâmetros medidos	100
4.2.1.2	Parâmetros calculados	101
4.2.1.2.1	Irradiância de Céu Claro	101
4.2.1.2.2	Varição da Irradiância do Céu Claro	102
4.2.1.3	Fotos da câmera de céu	103
4.2.2	Redes neurais	105

4.2.2.1	Rede neural LSTM	106
4.2.2.1.1	Camada LSTM	106
4.2.2.1.2	Camada Densa	108
4.2.2.2	Rede neural CNN	110
4.2.2.2.1	Camada de Convolução	110
4.2.2.2.2	Camada de <i>Pooling</i>	111
4.2.2.2.3	Camada de Ativação	112
4.2.2.2.4	Camada de Vetorização	113
4.2.2.3	Janelas Deslizantes	113
4.2.3	Métricas de desempenho	113
4.2.4	Algoritmo de Suavização	114
4.3	Resultados e Discussão	117
4.3.1	Arquitetura da rede neural híbrida CNN-LSTM.	117
4.3.2	Análise Qualitativa e Quantitativa da Previsão	118
4.3.3	Aplicação da previsão	123
4.4	Conclusão	125
5	CONSIDERAÇÕES FINAIS	131
	REFERÊNCIAS	133

Capítulo 1

Introdução Geral

A inserção de sistemas PVs em sistemas elétricos foi impulsionada nos últimos anos pelo avanço de suas tecnologias, diminuição dos seus custos e demanda social por fontes de energia de baixa emissão de carbono. No entanto, a participação da energia PV na matriz elétrica é limitada pela intermitência da fonte solar (WU; ZHANG; STERLING, 2022).

Esta intermitência representa um desafio significativo para a estabilidade e confiabilidade dos sistemas elétricos. À medida que a participação de fontes renováveis não despacháveis em uma matriz elétrica aumenta, cresce também a responsabilidade das usinas hidrelétricas, especialmente da energia armazenada em seus reservatórios, para equilibrar a oferta e a demanda (CASTRO; AMARAL; BRANDÃO, 2023).

Neste contexto, surge a questão de como manter o crescimento das fontes renováveis garantindo a segurança e confiabilidade do sistema elétrico. A flexibilidade emerge como um atributo cada vez mais relevante e estratégico (LUND et al., 2015). Embora a geração através de usinas termelétricas flexíveis seja uma alternativa disponível, seus custos são elevados e seu impacto ambiental contraria as metas de descarbonização assumidas pelo Brasil (EPE, 2021).

Este cenário desafia o Setor Elétrico Brasileiro a buscar soluções de flexibilidade mais alinhadas com a sustentabilidade. Uma abordagem promissora é a integração de BESS às usinas PVs, transformando-as em fontes de energia despacháveis (DENHOLM et al., 2017). Além disso, a incorporação de tecnologias como ASCs para previsão de sombreamento pode contribuir para mitigar os efeitos da intermitência solar (CHOW et al., 2011).

Os BESSs, além de possuírem baixa inércia (EPE, 2019), vêm se destacando devido às suas outras boas características, como adaptabilidade, controlabilidade (HANNAN et al., 2021), escalabilidade, alta proporção entre energia e peso (SALEH et al., 2018), ausência de efeito de memória e baixo auto descarregamento (EVANS; STREZOV; EVANS, 2012).

A queda recente no preço das baterias tornou o uso do BESS atraente em usinas PVs (EPE, 2021). De acordo com Hannan et al. (2021) e Bloomberg (2023), o preço das baterias de lítio-ion caiu de \$ 1100,00/kWh para \$ 156,00/kWh entre 2010 e 2019. Nos quatro anos seguintes (2019 a 2022) o preço estabilizou, apresentando em 2020 e 2021 leves quedas e em 2022 um leve crescimento causado pelo aumento do preço dos metais neste período, de acordo com Bloomberg (2022). A Bloomberg (2023) prevê que esta estabilidade no preço deva se manter até 2024, e para 2026, prevê que o preço cairá para \$100,00/kWh.

O BESS pode ser usado para prestar uma série de serviços ao sistema elétrico, descritos a seguir:

- A adoção do BESS em usinas PV pode auxiliar o Operador Nacional do Sistema Elétrico (ONS) no controle da rede. Caso solicitada, a usina PV pode contribuir com o fornecimento de energia reativa ao sistema distribuído, armazenando o excedente ativo.
- O BESS pode atuar na otimização do contrato da usina PV, no qual são estabelecidos limites de geração. Nos momentos em que a potência gerada ultrapassa esses limites, parte da geração é desperdiçada, de modo que a usina não pague multas. Nesses momentos, o BESS pode armazenar essa energia. Logo, a energia excedente que seria desperdiçada ou geraria multas, ao invés, gera lucro.
- O BESS pode maximizar os lucros também na arbitragem da venda de energia em usinas PV, armazenando energia quando o preço de venda é baixo (em horários fora de ponta, durante o dia), e descarregando em horários de ponta, quando o preço de venda de energia é alto (à noite).
- Ao sistema distribuído de energia, o BESS agrega uma série de melhorias técnicas, financeiras e ambientais, dentre elas: melhoria da qualidade de energia, mitigação do desvio de tensão, regulação de frequência, deslocamento de carga, nivelamento de carga, corte de pico de demanda (*peak shaving*) e diminuição nas emissões de gases do efeito estufa (DAS et al., 2018).
- O BESS tem grande utilidade também na diminuição da intermitência causada pelo sombreamento de nuvens. No momento do sombreamento ocorre uma queda abrupta na geração de potência, que chega a cair 80% (GANDOMAN et al., 2018). A rampa de potência aplicada no BESS com o objetivo de transformar a queda instantânea de potência em uma rampa suave pode ser iniciada antes ou após o início do sombreamento. Caso seja iniciada antes, é necessário algum método de previsão do sombreamento, que pode utilizar uma ASC associada com técnicas de previsão, normalmente relacionadas ao aprendizado de máquinas (SYED; KHALID, 2021).

Países que possuem uma alta inserção de energia PV na matriz elétrica sofrem com o problema da intermitência causada pelo sombreamento, e, portanto, regulamentam a variação máxima de potência injetada na rede elétrica por minuto ($\Delta P_G/min$), tornando necessária a aplicação de uma rampa de potência (SUKUMAR et al., 2018). Nesses países, a suavização dos efeitos de sombreamento em usinas PV é necessária para regularizar a usina PV e diminuir - ou eliminar - a quantidade de multas pagas devido à quebra do limite medido em $\Delta P_G/min$.

Pelos motivos acima expostos os BESSs têm um papel fundamental na substituição do uso de fontes de energia fóssil por fontes de energias renováveis, visto que o armazenamento de energia torna o sistema de geração de energia a partir de fontes renováveis mais seguro e confiável, e, portanto, justificando a necessidade do estudo dos BESS.

1.1 Contextualização

O maior BESS em operação na Europa, localizado no Reino Unido, possui potência e capacidade de 98 MW/196 MWh (INTERNATIONAL, 2023). No Reino Unido, BESSs fornecem 27 GWh por ano e proveem cerca de $\frac{1}{4}$ da capacidade de regulação de frequência da rede elétrica (IRENA, 2019).

O maior BESS instalado na Ásia fica em Singapura. O BESS de 285MWh foi instalado com o objetivo de complementar os esforços de maximização da adoção da fonte solar de energia. Além de fornecer energia, o BESS fornece serviços de regulação para aumentar a resiliência da rede elétrica de Singapura e gerencia a volatilidade no fornecimento de energia (CHANNEL, 2023).

Nos Estados Unidos, o sistema elétrico de Porto Rico é isolado, pequeno e possui grande penetração de fontes renováveis de energia. Portanto, já em 2012 foram estabelecidos requisitos para conectar sistemas PV no sistema elétrico visando reduzir a sua instabilidade. Dentre esses requisitos, foi estabelecida a variação máxima de 10% de $\Delta P_G/min$ (IRENA, 2019). As usinas PV de Porto Rico utilizam diferentes métodos para se manter dentro dessa regra. Dentre os métodos, há usinas PV que utilizam BESSs, geradores a diesel e métodos reativos que não precisam de outra fonte de energia, visto que cortam e desperdiçam a potência PV em excesso.

Ainda em Gevorgian, Murali e Dan (2019), é argumentado que a regra de 10% de $\Delta P_G/min$ em Porto Rico deve ser reavaliada, pois ao considerar a rede elétrica em sua totalidade, a intermitência causada pela soma de todas usinas PV não é tão grande. A intermitência causada por cada usina PV é diluída, quando se considera a intermitência total das ilhas. Isso ocorre pois a intermitência individual de cada usina não ocorre ao mesmo tempo. Gevorgian, Murali e Dan (2019) concluem que o acoplamento de BESS

às usinas PV reduziriam apenas de 15% para 10% a variação $\Delta P_G/min$ total de Porto Rico. Porém, essa conclusão considera a penetração de renováveis na época da publicação (2019), sem considerar a projeção de 100% de energia renováveis em Porto Rico até 2050.

Em países grandes com pouca inserção de fontes de energia renovável intermitentes na matriz elétrica, normalmente a variação máxima de $\Delta P_G/min$ não é regulamentada devido à diluição de seus efeitos. A intermitência causada pela fonte solar no Sistema Interligado Nacional (SIN) brasileiro, por exemplo, é baixa. Isso ocorre porque o SIN possui uma grande extensão longitudinal, na qual o meio-dia solar ocorre com uma diferença de mais de três horas ao longo de sua extensão, diluindo a intermitência individual causada por cada usina PV.

Outro fator que faz com que a instabilidade elétrica no SIN não seja tão grande é o fato de o país atualmente não possuir grande penetração de fontes renováveis intermitentes. No entanto, essa situação está mudando rapidamente. Com o crescimento previsto da capacidade instalada PV (EPE, 2023), os problemas causados pela intermitência PV tendem a se intensificar, o que poderá levar à necessidade de regulamentação da variação máxima de $\Delta P_G/min$.

Essa transição energética em curso no Brasil já está trazendo desafios para o SIN. Um exemplo que ilustra essa complexidade foi o blecaute elétrico ocorrido em 15 de agosto de 2023 (CASTRO; AMARAL; BRANDÃO, 2023). Nesse evento, a oferta de energia excedeu a demanda, levando o ONS a solicitar que algumas usinas reduzissem sua geração para manter a integridade da rede elétrica, e alguns equipamentos não responderam corretamente à solicitação de diminuição de fornecimento de energia. Esse tipo de situação, onde o excesso de energia produzida por fontes renováveis precisa ser descartado, principalmente aos finais de semana, evidencia a necessidade de soluções flexíveis de armazenamento de energia, como o BESS.

1.2 Justificativa

A inclusão de BESSs em sistemas elétricos é um passo crucial para os esforços de mitigação das mudanças climáticas e transição para uma matriz elétrica mais sustentável.

Caso os sistemas PVs não tenham a sua potência suavizada através de tecnologias como o BESS, o crescimento da energia PV na matriz elétrica será limitado devido aos desafios técnicos e econômicos associados à sua intermitência.

1.3 Objetivos

Com a realização deste trabalho, o seguinte objetivo geral é proposto:

- Desenvolver uma solução que mitigue os efeitos de intermitência em usinas PV/BESSs, de modo que essas usinas não causem instabilidade na rede elétrica e a participação da fonte solar na matriz elétrica possa ser maximizada.

De forma a atingir o objetivo geral, os três seguintes objetivos específicos foram estabelecidos:

1. Desenvolver e implementar um sistema de comunicação (SC) escalável em uma usina PV/BESS com ASC, utilizando exclusivamente software de código aberto, visando a coleta de dados de alta qualidade para suporte à tomada de decisões e ao desenvolvimento de ferramentas de otimização e controle da usina.
2. Otimizar a projeção da potência das baterias em uma usina PV/BESS, maximizando o lucro diário enquanto se preserva a vida útil das baterias. A potência otimizada serve como *set point* de operação do BESS;
3. Desenvolver um método de previsão de sombreamento baseado em fotos capturadas pela ASC, permitindo a antecipação da suavização da potência gerada;

1.4 Organização do Documento

O corpo principal deste trabalho está estruturado em três capítulos, cada um dedicado a um dos três objetivos específicos previamente mencionados. Cada capítulo possui suas próprias seções de introdução, metodologia, resultados e conclusão, no entanto, todos convergem para o cumprimento do objetivo geral. Abaixo segue a descrição do que é abordado em cada capítulo:

- Capítulo 2 - É descrito o desenvolvimento dos SCs de uma Usina PV/BESS com ASC, abordando a coleta e sincronização de dados essenciais para a operação da usina. Os dados coletados e sincronizados formaram o conjunto de dados que é utilizado nos Capítulo 3 e Capítulo 4.
- Capítulo 3 - É descrito o desenvolvimento da projeção da potência do BESS. A otimização desta projeção é realizada tendo como entrada a previsão da geração de energia PV e a precificação de venda no mercado de energia de curto prazo. Esta projeção é amostrada em 10 min.
- Capítulo 4: É descrito o desenvolvimento da previsão de queda de irradiância baseada em fotos da ASC. Esta previsão é utilizada para que a usina PV/BESS possa suavizar, de forma antecipada, a queda abrupta de geração que acontece devido ao sombreamento. Esta previsão é amostrada em 20 s.

- Capítulo 5: São feitas as considerações finais do trabalho.

1.5 Limitações

A projeção realizada no Capítulo 3 depende de uma previsão de geração de energia amostrada em 10 min. No entanto, o desenvolvimento desta previsão não é descrito neste trabalho. Esta previsão foi simulada, a partir da inserção de um erro na potência real.

Já no Capítulo 4, é descrita uma previsão de queda de geração, amostrada em 20 s. De forma a validar o uso desta previsão, foi realizada uma projeção realizada a partir desta previsão, no entanto, esta projeção foi descrita de forma simplificada, não foi aprofundada.

1.6 Agradecimentos

O autor agradece à Huawei pelo apoio financeiro e suporte ao desenvolvimento deste trabalho, proporcionado ao longo do projeto de Pesquisa e Desenvolvimento de número 1504.11.1021.

Capítulo 2

Desenvolvimento de Sistemas de Comunicação de uma Usina PV/BESS com ASC

Resumo

A operação, manutenção e monitoramento eficientes de uma usina PV estão intrinsecamente ligados à acessibilidade e confiabilidade dos dados, que, por sua vez, dependem da robustez dos seus SCs. À medida que novas tecnologias surgem e novos equipamentos são integrados às usinas PV, o SC enfrenta novos desafios, descritos neste trabalho. Os equipamentos recentes integrados às usinas PV incluem o BESS, que transforma a usina PV em uma planta despachável, e a ASC, que permite que a previsão de eventos de sombreamento seja feita. Neste trabalho, dois SCs foram desenvolvidos utilizando apenas software de código aberto, sendo que o primeiro foi projetado para comunicação entre os equipamentos PV e BESS, e o segundo foi desenvolvido para coletar fotos da ASC. Os requisitos dos SCs foram definidos com base nas aplicações que controlam a usina PV e na norma IEC-61724-1 para dados PV. Após o desenvolvimento, os SCs foram instalados em uma usina PV/BESS com ASC, e a interação entre os dados coletados desses dois sistemas é apresentada e discutida.

Palavras-chaves: fotovoltaico, armazenamento, energia, baterias, Modbus, comunicação.

Abstract

The efficient operation, maintenance and monitoring of a PV plant are intrinsically linked to data accessibility and reliability, which, in turn, rely on the robustness of the SC. As new technologies arise and newer equipment is integrated into the PV plants, the SC faces new challenges that are described in this work. Newer integrated equipment in PV plants includes the battery energy storage system BESS that transforms the PV plant into a dispatchable plant and the ASC that enables the prediction of shading events. In this paper, two SCs were developed using only open-source software, in which the first was designed for seamless communication between the PV and BESS equipment, while the second was tailored to collect photographs from the ASC. The requirements of the SC were defined based on the applications that control the PV plant, and on the industry-standard IEC-61724-1 norm for PV data. After being developed, the SCs were installed in a PV/BESS plant, and the interaction between the data obtained from these two systems is presented and discussed.

Keywords: photovoltaic, storage, energy, batteries, Modbus, communication.


2.1 Introdução

Fontes de energia como o Sol e o vento agregam valor ao sistema elétrico pois são limpas e renováveis, no entanto deve-se ter uma atenção quanto à qualidade e robustez do fornecimento de energia elétrica por essas fontes em razão da intermitência. A intermitência é um dos grandes desafios para tornar a matriz elétrica menos poluente e renovável.

Uma forma de reduzir a intermitência em usinas de energia renovável é a partir do uso de acumuladores de energia. Desse modo, é possível armazenar energia quando ela é produzida em excesso, de modo que possa ser usada em momentos nos quais a fonte de energia renovável não supre o consumo de energia elétrica. Dentre os acumuladores de energia, o BESS de lítio-ion vem se destacando devido à redução em seu preço nos últimos anos.


O uso de BESS agrega uma série de melhorias técnicas, financeiras e ambientais ao sistema elétrico, dentre elas: melhoria da qualidade de energia, mitigação do desvio de tensão, regulação de frequência, deslocamento de carga, nivelamento de carga, corte do pico de demanda (*peak shaving*) e arbitragem na venda de energia (*time shifting*) (DAS et al., 2018).

Figura 1 – *Peak shaving*.



Fonte: Autor.

Das melhorias citadas, o *peak shaving* (Fig. 1) permite ao consumidor que possui um BESS acoplado ao seu sistema PV de geração distribuída diminuir os seus custos com a demanda contratada. Com a diminuição do pico de consumo na rede elétrica, o *peak shaving* beneficia também o sistema elétrico como um todo, visto que tem seus investimentos em infraestrutura reduzidos. Já o *time shifting* (Fig. 2) propicia à usina que vende energia elétrica armazenar a energia produzida quando o preço de venda é baixo, e fornece-la à rede elétrica quando o preço de venda é alto.


Figura 2 – *Time shifting*.

Fonte: Autor.

Outro equipamento que agrega valor ao ser utilizado em usinas PV, além do BESS, é a ASC, que tira fotos das nuvens de modo a prever o momento no qual ocorrerá o sombreamento. Tendo essa previsão em mãos, é possível realizar antecipadamente ao sombreamento uma rampa de suavização, de modo a transformar as quedas abruptas de potência em rampas suaves.

Como exemplo da utilidade das ASCs em usinas PV, na Fig. 3, aos 15 min é previsto que aos 25 min ocorrerá um sombreamento, que causará uma queda de 100 % na potência fotovoltaica gerada (P_{PV}). De forma a evitar a queda abrupta da potência fornecida à rede elétrica (P_G), as baterias armazenam a energia produzida entre os min 15 e 25, de forma a suavizar a queda de potência prevista.

Figura 3 – Queda abrupta causada pelo sombreamento.



Fonte: Autor.

Na Seção 2.1.1 é apresentado um resumo dos principais trabalhos que serviram de base para o desenvolvimento dos SCs deste trabalho.

2.1.1 Revisão da Literatura

A norma IEC 61724 (IEC, 2017) especifica os dados que devem ser coletados em usinas PV, juntamente de seus intervalos de amostragem e armazenamento. Em Biasi et al. (2020), a norma IEC 61724 foi utilizada para estabelecer quais parâmetros deveriam ser medidos em uma usina PV dedicada a propósitos de pesquisa científica. O registrador de dados Campbell Scientific CR1000 foi utilizado para coletar os dados da estação

meteorológica e dos equipamentos PVs. Todos os parâmetros listados na IEC 61724 foram medidos, com exceção da irradiância do plano do arranjo (*plane of array irradiance* - *POA*, em kW/m^2) e da direção do vento (m/s), devido a restrições orçamentárias.

Na Tabela 1 são descritos alguns dos parâmetros que devem ser medidos em uma usina PV de acordo com a norma IEC 61724, como a irradiância horizontal global (*global horizontal irradiance* - *GHI*), irradiância difusa horizontal (*diffuse horizontal irradiance* - *DHI*) e a irradiância direta normal (*direct normal irradiance* - *DNI*).

Tabela 1 – Parâmetros medidos em usinas PV descritos na norma IEC 61724-1 (ANSI, 2021).

Tipo	Parâmetro	Símbolo	Unidade
Parâmetros solares	Irradiância no plano do arranjo	<i>POA</i>	W/m^2
	Irradiância global horizontal	<i>GHI</i>	W/m^2
	Irradiância difusa horizontal	<i>DHI</i>	W/m^2
	Irradiância normal direta	<i>DNI</i>	W/m^2
Parâmetros ambientais	Temperatura ambiente média	-	$^{\circ}\text{C}$
	Umidade relativa	-	-
	Velocidade do vento	-	m/s
	Direção do vento	-	graus
	Proporção de sujidade	-	-
	Precipitação	-	mm
Parâmetros elétricos	Tensão do arranjo (CC)	-	V
	Corrente do arranjo (CC)	-	A
	Potência do arranjo (CC)	-	kW
	Tensão de saída (CA)	-	V
	Corrente de saída (CA)	-	A
	Potência de saída (CA)	-	kW
	Energia de saída	-	kWh
	Fator de potência	-	-

CC - corrente contínua; CA - corrente alternada.

Fonte: Adaptado de IEC (2017).

Embora alguns dos parâmetros da Tabela 1 sejam medidos pelos próprios equipamentos da usina PV, como o inversor, sensores adicionais são necessários em alguns casos. Em Madeti e Singh (2017), diferentes tipos de sensores foram comparados: piranômetros e células solares para medir dados solarimétricos; termopares e termopilhas para medir as temperatura ambiente e do módulo PV; amperímetros e voltímetros para medir parâmetros elétricos, entre outros.

O controlador é responsável por receber e enviar dados para o registrador de dados, e a seleção adequada do controlador depende do tamanho da usina PV. Para sistemas PV residenciais, soluções de baixo custo com microcontroladores são adequadas. Em Cheddadi et al. (2020), sensores que se comunicam enviam dados para um microcontrolador ESP32,

utilizando o protocolo *Inter-Integrated Circuit*. Os dados são pré-processados no ESP32, enviados para a nuvem via WiFi, armazenados no banco de dados InfluxDB e apresentados em um *dashboard* desenvolvido com o Grafana.

No entanto, para usinas PVs maiores com múltiplas *strings*, pode ser necessário um controlador lógico programável robusto. Em Ali et al. (2021), um Sistema de Supervisão e Aquisição de Dados (SCADA, do inglês *Supervisory Control And Data Acquisition*) foi desenvolvido para uma microrrede que incluía duas usinas PV e um BESS. Um controlador Schneider Modicon M221 foi usado para estabelecer a comunicação com o protocolo Modbus em mídia física Ethernet. O SCADA recebe dados do inversor, controlador de bateria, medidor de energia e medidor de energia. O uso do SCADA facilitou o controle da microrrede e melhorou sua eficiência.

Na literatura, são citados diversos meios nos quais se pode transmitir os dados. Pode-se dividi-los entre meios físicos (cabo coaxial, Ethernet, fibra ótica, *power line communication* - PLC) e meios sem fio (WiFi, GSM, 5G). Em plantas pequenas, residenciais ou comerciais, é prático o uso da própria rede Ethernet do local para a transmissão dos dados, como apresentado em Martirano et al. (2019).

Já em sistemas PV centralizados, é aconselhável a instalação de uma rede de transmissão dedicada aos dados, como em Ndukwe, Iqbal e Khan (2020). Nesse trabalho, o sistema SCADA desenvolvido transmite os dados utilizando LoRa, protocolo de rede que usa radiofrequências de longo alcance e que tem um baixo consumo de energia.

Outra solução interessante e de baixo custo, quando há a necessidade de longo alcance, é a transmissão de dados utilizando a própria linha de energia, i.e., PLC. Han, Lee e Kim (2015) utilizaram a PLC em uma usina PV residencial, colocando codificadores de PLC entre os equipamentos, evitando a instalação de cabeamento adicional e reduzindo os custos do sistema.

2.1.2 Objetivo Geral

O objetivo geral deste capítulo é desenvolver dois SCs de uma usina PV/BESS com ASC, de modo que sejam coletados dados para suporte à tomada de decisões e ao desenvolvimento de ferramentas de otimização e controle da usina PV.

2.1.3 Objetivos Específicos

Este capítulo possui como objetivos específicos:

- Estabelecer os requisitos de SCs em usinas PV, de modo a identificar quais parâmetros devem ser medidos;

- Desenvolver SCs que permitam que a usina possa ser controlada;
- Coletar e armazenar dados de modo que sejam formados conjuntos de dados, visando a realização dos estudos do Capítulo 3 e Capítulo 4.

2.1.4 Contribuições

As principais contribuições deste trabalho incluem:

- desenvolvimento de um SC escalável que utiliza apenas *software* de código aberto para reduzir o preço da solução;
- adaptação de uma ASC noturna em diurna, de modo que a ASC possa ser utilizada no estudo de queda de geração PV causada por sombreamento.
- sincronização da taxa de amostragem das fotos do ASC com os dados de séries temporais, de forma que estes dados possam ser utilizados em estudos do sombreamento.

Neste capítulo é apresentado o desenvolvimento de dois SCs para uma planta PV/BESS de 10 kW localizada na UFPB, no Brasil. Apesar do tamanho reduzido, a planta foi construída para emular plantas de grande porte e investigar a integração de BESSs no Sistema Elétrico Nacional (SIN) brasileiro. Portanto, um dos principais requisitos dos SCs é sua capacidade de serem escaláveis. Além disso, um pré-requisito crucial para o projeto foi a utilização exclusiva de software de código aberto para minimizar os custos.

As fotos do ASC são entradas do Previsor de Queda de Energia, juntamente com o *GHI* coletado medido na estação meteorológica e outros dados de séries temporais. Neste caso, o requisito é que todas as entradas devem ser sincronizadas com a mesma taxa de amostragem e marcas de tempo iguais. Considerando que cada fotografia leva cerca de 20 ± 3 s para ser capturada, a sincronização das fotos com os dados de séries temporais é um desafio abordado neste capítulo.

Os dados coletados e os SCs possibilitarão pesquisas adicionais sobre temas como otimização do despacho das baterias, análise econômica e previsão da geração de energia. A precisão desses estudos depende muito da qualidade dos dados coletados e do SC, justificando a relevância deste trabalho.

2.2 Metodologia

Nesta Seção, descreve-se a metodologia usada para a construção dos dois SCs.


2.2.1 Equipamentos da planta PV/BESS com ASC

No Brasil, há usinas PV conectadas ao SIN com potência nominal próxima a 30 MWp, contendo centenas de *strings* com cerca de 30 módulos PV cada. De modo a emular uma usina PV de geração centralizada com armazenamento de energia em baterias, foi montado um *setup* experimental no bloco KLM da UFPB, Campus I, em João Pessoa/PB, contendo duas strings de módulos PV que totalizam uma potência de 10,07 kWp. Os equipamentos do sistema incluem:

- Inversor - Huawei SUN2000 5KTL-L1;
- BESS - Huawei LUNA2000 10 kWh e 5kW;
- Medidor de energia - Huawei Smart Power Sensor DTSU666-H;
- Módulos PV - 19 módulos Jinko JKM530M-72HL;
- Estação meteorológica - Ammonit;
- ASC - Starlight Oculus All Sky Cam.

Na Fig. 4, mostram-se os equipamentos e as suas conexões elétrica e de comunicação. Cada um dos equipamentos é descrito nos próximos após a 4.

Figura 4 – Conexões elétricas e de dados entre os equipamentos.



Fonte: Autor.


O inversor Sun2000 5KTL-L1 possui duas entradas MPPTs (rastreador de ponto de mais potência, do inglês *maximum power point tracking*), sendo uma com dez módulos PV conectados e outra com nove. Apesar de o inversor possuir potência nominal de 5 kW, o Sun2000 consegue fornecer ao mesmo tempo 5 kW à rede elétrica e mais 5 kW às

baterias. Conforme se vê na Figura 4, toda comunicação enviada pelo BESS e medidor de energia passa primeiramente pelo inversor, antes de chegar ao SCADA local. O inversor também pode ser visto na Fig. 5(a), marcado com o número 2.

O BESS da Huawei modelo Luna 2000 - marcado com o número 1 na Fig. 5(a) - é composto por um controlador de potência de 5 kW e dois módulos de bateria de 5 kWh cada. As células da bateria são de fosfato de lítio ferro (LiFePO₄), material adequado ao uso em larga escala visto que possui alta energia específica, ausência de efeito de memória e baixo auto descarregamento (EVANS; STREZOV; EVANS, 2012).

O medidor inteligente de energia da Huawei modelo Smart Power Sensor DTSU666-H0 está instalado dentro da Backup Box modelo B0 - equipamento 3 da Fig. 5(a). De maneira semelhante ao medidor de energia da concessionária, o medidor inteligente de energia tem a função de medir a energia, tensão e corrente que trafegam bidirecionalmente entre o sistema de geração e a rede elétrica. Esse medidor mede ainda a frequência, fator de potência, potência ativa, reativa, entre outros parâmetros elétricos.

Figura 5 – Principais equipamentos do setup experimental PV/BESS, que incluem o (a) inversor, medidor de energia, BESS, (b) ASC, módulos PV, (c) SCADA das fotos da câmera e (d) estação meteorológica.



Fonte: Autor.

A estação meteorológica Ammonit - Fig. 5(d) - encontra-se instalada a 10 m de altura, em cima do laboratório LABRADS na UFPB. Os sistemas que dependem dos dados da estação meteorológica são os preditores de geração de energia. A previsão da quantidade de energia que será gerada depende, principalmente, da irradiância, temperatura ambiente e velocidade do vento. Os instrumentos de medição contidos na estação meteorológica Ammonit são descritos abaixo, seguido pelos parâmetros que medem:

- Anemômetro - velocidade do vento, em m/s;

- Biruta - direção do vento, em graus;
- Piranômetro - GHI , em W/m^2 ;
- Piranômetro sombreado - DHI , em W/m^2 ;
- Higrômetro - precipitação, em mm;
- Termômetro - temperatura do ar ambiente, em $^{\circ}C$;
- Barômetro - pressão, em kPa.

Todos os equipamentos da usina, com exceção da ASC, utilizam nativamente o protocolo Modbus para a comunicação. Cada parâmetro lido a partir do protocolo Modbus é identificado a partir de um endereço.

Os endereços dos registros Modbus da estação meteorológica Ammonit são configuráveis no site do fabricante Ammonit (2023), sendo possível, por exemplo, configurar os endereços dos parâmetros descritos acima como sendo 01 a 07.

A ASC foi instalada próxima aos módulos PV, conforme se vê na Fig. 5(b). Desse modo, o momento no qual a nuvem inicia o sombreamento na imagem coletada coincide com o tempo no qual ocorre a queda de potência PV lida no inversor. As fotos podem ser comparadas também com a variação nas irradiâncias lidas na estação meteorológica, GHI , DNI e DHI .

O desenvolvimento do SC da ASC é descrito na Seção 2.2.4, e antes disso, o desenvolvimento da comunicação dos equipamentos que se comunicam por Modbus - equipamentos da estação Ammonit da Fig. 5(d) e equipamentos PV/BESS da Fig. 5(a) - é descrito na Seção 2.2.3.

Os requisitos dos dados foram estabelecidos a partir das aplicações que irão utilizar os dados e a partir de uma norma referente a dados de usinas PVs. Os requisitos são descritos na Seção 2.2.2.

2.2.2 Requisitos de dados em usinas PV/BESS.

Cada aplicação que utiliza dados e portanto utiliza os SCs de uma usina possui uma especialidade, e são chamadas de sistemas especialistas (SEs). Três SEs utilizados para o controle e gerenciamento de usinas PV/BESS são o preditor de geração de energia, o preditor de queda de geração de energia e o sistema de gerenciamento de energia (*energy management system* - EMS). O EMS de usinas PV/BESS é quem faz a projeção da potência do BESS, feita a partir das previsões de geração e de queda de geração. Cada uma dessas aplicações tem como entrada diferentes dados, de diferentes origens. Nas Tabela 2, Tabela 3 e Tabela 4 são descritas as características dos dados utilizados por essas três aplicações.

Tabela 2 – Características do SE Preditor de Geração de Energia.

	Função:	Prever a geração PV.
	Objetivo:	Permitir que um planejamento sobre a operação da usina seja feito.
	Dados de entrada:	Dados históricos climáticos e dos equipamentos PV/BESS; dados em tempo real da estação meteorológica e dos equipamentos PV/BESS.

Fonte: Autor.

Tabela 3 – Características do SE Preditor de Queda de Geração de Energia.

	Função:	Prever a queda de geração PV
	Objetivo:	Auxiliar a suavização da potência injetada na rede, causada pelo sombreamento PV
	Dados de entrada:	Dados históricos climáticos e dos equipamentos PV/BESS; dados em tempo real da estação meteorológica e dos equipamentos PV/BESS.

Fonte: Autor.

Tabela 4 – Características do SE EMS.

	Função:	Gerenciar a energia do sistema PV/BESS
	Objetivo:	Controlar os equipamentos da usina de modo que o lucro seja maximizado
	Dados de entrada:	Dados em tempo real da usina PV/BESS.

Fonte: Autor.

Além das aplicações que fazem parte da usina PV, os dados também são importantes para os diferentes *stakeholders* (partes interessadas) do projeto, descritos em IEA (2021): investidores, gerentes de projeto, auditores de desempenho, fabricantes de equipamentos e fornecedores de serviços.

No presente trabalho, é apresentado o desenvolvimento da comunicação entre os equipamentos de uma usina PV/BESS com ASC e os seus SCs. A integração desses equipamentos tem o objetivo de emular uma usina PV centralizada em escala reduzida, de modo a estudar a inserção de um BESS de Li-íon em usinas PV conectadas ao SIN.

Após o desenvolvimento da comunicação entre os equipamentos e da coleta dos seus dados, podem ser realizados vários estudos sobre esse sistema PV/BESS. Dentre os estudos estão incluídos: a otimização da projeção da potência do BESS de modo a maximizar o seu retorno financeiro; a previsão baseada em dados históricos de geração de energia; a previsão de queda de potência baseada em imagens da ASC; o desenvolvimento de uma rampa de suavização de potência, entre outros. A necessidade desses estudos de receberem dados


íntegros, confiáveis e com pouca quantidade de dados faltantes, justifica este trabalho, que se trata de desenvolver uma comunicação confiável entre os equipamentos PV/BESS.

Ao longo deste trabalho, descreve-se o desenvolvimento de um aquisitor de dados feito com o *framework* pyModbusTCP em linguagem Python. Os equipamentos (inversor, medidor de energia, BESS e estação meteorológica) enviam os dados através do meio físico Ethernet, usando o protocolo ModbusTCP. O cliente Modbus que recebe esses dados é um computador conectado na Intranet à qual os equipamentos estão conectados. Ademais, ele trata os dados, e direciona-os à nuvem para serem armazenados pelo InfluxDB, de modo a serem usados pelas diferentes aplicações que serão desenvolvidas.

2.2.3 SC em Modbus

O Modbus é um protocolo de comunicação assíncrona, no qual o servidor envia os dados quando é solicitado por um cliente (MODBUS, 2012). Apesar de antigo, o protocolo ainda é bastante empregado nos dias atuais, devido, principalmente, a ser um protocolo aberto. Cada pacote de dados enviado pelo servidor Modbus possui um cabeçalho e um protocolo de unidade de dados (*protocol data unit* - PDU). Os protocolos Modbus RTU e Modbus TCP compartilham a estrutura básica de dados do PDU, em verde, conforme se ilustra na Fig. 6. Já o *frame* completo (mensagem completa), chamado de *application data unit* (ADU), apresenta diferenças entre o do Modbus RTU e o do Modbus TCP.

Figura 6 – Frame do Modbus RTU e do Modbus TCP.



Fonte: Modbus (2012).

Nota-se na Fig. 6 que o *frame* do Modbus RTU é composto por um endereço (SlavID) em azul, pelo PDU em verde e por uma checagem de erro (CRC) em amarelo. O Modbus TCP não possui a checagem de erro no final, visto que ele se utiliza da checagem de erro CRC-32 do protocolo TCP/IP. O *frame* do Modbus TCP possui apenas um cabeçalho (MBAP Header) em azul e o PDU em verde. A composição do cabeçalho é descrita na Tabela 5.

Tabela 5 – Descrição do cabeçalho do Modbus TCP.

Campo	Bytes	Descrição	Cliente	Servidor
<i>Transaction ID</i>	2	Identificação da solicitação	Inicializado pelo cliente	Recopiado pelo servidor
<i>Protocol ID</i>	2	0: protocolo Modbus	Inicializado pelo cliente	Recopiado pelo servidor
<i>Lenght</i>	2	Número de <i>bytes</i>	Inicializado pelo cliente	Alterado pelo servidor
<i>Unit ID</i>	1	Identificação do servidor	Inicializado pelo cliente	Alterado pelo servidor

Fonte: Autor.

Da Tabela 5, verifica-se que o cabeçalho possui um tamanho de sete *bytes*. A maior parte do cabeçalho que foi recebida pelo servidor é devolvida ao cliente sem nenhuma alteração. Somente o campo *Length* é alterado, pois identifica qual o tamanho do PDU que foi enviado ou recebido. O campo *Protocol ID* é sempre igual a 0, identificando que a mensagem segue o protocolo Modbus. O campo *Unit ID* identifica qual servidor o cliente deseja que envie uma resposta. A comunicação, ou seja, o envio do ADU, é sempre iniciada pelo cliente. O *frame* é enviado a todos os servidores na rede, porém somente o servidor que possuir o *Unit ID* do *frame* envia uma resposta. Neste caso, a porta TCP padrão na qual o servidor envia os dados é a 502.

Tabela 6 – Tipos de dados transmitidos.

Tabelas primárias	Formato	Read/Write	Comentários
<i>Discrete input</i>	1 bit	RO	Pode ser fornecido por um sistema I/O
<i>Coils</i>	1 bit	RW	Pode ser alterado por um aplicativo
<i>Inputs registers</i>	16 bits	RO	Pode ser fornecido por um sistema I/O
<i>Holding registers</i>	16 bits	RW	Pode ser alterado por um aplicativo

Fonte: Autor.

Na Tabela 6, apresentam-se os tipos de dados que podem ser transmitidos via Modbus. Os dados podem ser discretos (0 ou 1), caso sejam *discrete inputs* ou *coils*, ou valores numéricos de até dois *bytes* por registro, caso sejam do tipo *input* ou *holding registers* (i.e., registros). Na necessidade de transmitir um dado maior que dois *bytes*, é necessário que o dado seja acomodado em dois ou mais registros.

Para o desenvolvimento do cliente, foi utilizado o pacote pyModbusTCP (2023) em Python, devido a facilidade no seu uso. O pyModbusTCP lida com o cabeçalho a partir da classe pyModbusTCP.client, sendo simples a sua configuração. Dessa maneira, só é necessário gerenciar o PDU da mensagem. O PDU contém o código da função (leitura ou escrita), o endereço do registro e o dado em si.

O cliente desenvolvido faz a leitura dos parâmetros, alarmes e status dos equipamentos PV/BESS, e também escreve em alguns registros. O *script* em Python do cliente é um programa leve, que não demanda grandes requisitos de hardware. O *script* é executado

em um computador na Intranet dos equipamentos e, caso fosse necessário, poderia ser substituído por um microcontrolador.

Cada dado enviado por cada equipamento possui um registro (endereço) específico. Em Solar Inverter Modbus Interface Definitions (HUAWEI, 2021), são informados quais são os registros de leitura e escrita dos equipamentos utilizados da Huawei: inversor Sun2000 5KTL, BESS LUNA2000 S0 e Smart Power Sensor DDSU666-H. Foi criada uma tabela contendo esses registros, incluída em formato de DataFrame dentro do *script* do cliente Modbus. Parte desses registros são apresentados na Tabela 7.

Na primeira coluna da Tabela 7, descreve-se o dado informado pelo registro e o equipamento que o origina. Na segunda coluna, informa-se se o dado pode ser lido (*read only* - RO), escrito (*write only* - WO), ou lido e escrito (*read and write* - RW). Na terceira coluna, informa-se a unidade do dado. Na quarta coluna, informa-se o coeficiente de ordem de grandeza, ou seja, indica quantas casas decimais o dado tem. Na quinta coluna, informa-se qual o número identificador do registro. Ademais, observa-se na Tabela 7 que os registros dos equipamentos inversor, BESS e *smart sensor* que começam com o número 3 são registros de somente leitura, e os que começam com 4, são de escrita, ou de leitura e escrita.

Tabela 7 – Exemplos de registros dos equipamentos Inversor Sun2000, BESS Luna2000 e Smart Power Sensor DDSU666-H.

Descrição	Read/Write	Unidade	Coeficiente	Registro
Inversor - Hora	RW	Epoch	1	40000
Inversor - Alarme 1	RO	N/A	1	32008
Inversor - Tensão do PV1	RO	V	10	32016
Inversor - Corrente do PV1	RO	A	100	32017
Inversor - Energia diária	RO	kWh	100	32114
Inversor - Potência ativa	RO	kW	1000	32080
Inversor - Fator de potência	RW	N/A	1000	40122
BESS - SOC	RO	N/A	10	37760
BESS - Carga total	RO	kWh	100	37780
BESS - Tensão	RO	V	10	37003
BESS - Corrente	RO	A	10	37021
BESS - Temperatura	RO	°C	10	37022
BESS - Modo: carga/descarga	WO	N/A	1	47100
BESS - Potência de carga	RW	kW	1000	47247
BESS - Potência de descarga	RW	kW	1000	47249
Sensor - Tensão da rede elétrica	RO	V	10	37101
Sensor - Frequência da rede elétrica	RO	Hz	100	37118
Sensor - Energia	RO	kWh	100	37119

RO - *read only*; RW - *read and write*; WO - *write only*.

Fonte: Autor.

Como um exemplo de leitura realizada pelo cliente, ao ler a tensão da primeira *string* conectada no inversor, é utilizado o registro 32016, que tem o formato inteiro e a

unidade em volts. Esse registro possui coeficiente igual a 10, indicando que o dado lido deve ser dividido por 10, de modo a ser obtido o valor da tensão real, com uma casa decimal. Os dados que possuem formatos diferentes de números inteiros, como os formatos *string*, *bitfield* e *float*, antes de serem lidos, precisam ser decodificados para serem compreendidos. Esse tratamento dos dados faz a conversão do dado lido no formato inteiro para o formato original do dado transmitido. O formato *bitfield*, no exemplo do registro 32008 na Tabela 7, indica que cada bit no registro possui um significado. Por exemplo, cada bit lido no registro 32008 (Alarm 1 do inversor) informa um alarme diferente. A posição do bit que tem seu valor igual a true (ou igual a 1) indica qual mensagem de alarme foi ativada. Caso o valor lido no registro 32008 seja igual ao inteiro 18 (10010 em binário), ele retorna o primeiro e quarto alarmes descritos na tabela de alarmes em Huawei (2021).

2.2.4 SC da ASC

O principal objetivo da ASC, na Fig. 5(b), é captar fotos quando solicitada e enviá-las ao armazenamento. Estas fotos são utilizados pelo SE Preditor de Queda de Geração, descrito na Tabela 3, para que o momento do sombreamento seja previsto. As fotos capturadas do céu, combinadas com os dados obtidos da estação meteorológica, servem como entradas para treinar um algoritmo de aprendizagem de máquina que prevê o sombreamento.

A ASC utilizada para capturar fotos do céu foi a Starlight Express 150 (STARLIGHT, 2024), que é uma câmera preto e branco com lente olho de peixe usada para capturar um ângulo amplo de 150° do céu. Esta câmera é originalmente projetada para fotos de longa exposição de estrelas à noite, logo as fotos tiradas durante o dia tendem a ficar muito brilhantes.

Para que a câmera possa capturar fotos das nuvens durante o dia, um filtro plano chamado ND 1000 foi colocado acima da lente olho de peixe. Isso reduziu a iluminância que entra na lente, mas resultou em algum reflexo nas imagens devido à combinação da lente curva (olho de peixe) e do filtro plano. Esse problema poderia ser resolvido colocando o filtro abaixo da lente, mas por enquanto isso não foi feito. Esses reflexos não são muito estéticos, mas não necessariamente prejudicarão a atuação do SE Preditor de Queda de Geração. As implicações desses reflexos nas fotos do ASC não foram avaliadas e podem ser abordadas em trabalhos futuros.

O cabo USB da ASC foi conectado a um microcontrolador Raspberry Pi 3B+ no qual o SC foi instalado, conforme apresentado na Fig. 5(c). O microcontrolador foi conectado a uma rede local via cabo Ethernet, que também serve como fonte de alimentação para a câmera por meio do padrão *Power over Ethernet* (PoE).

As fotos da ASC foram capturadas usando um *script* disponível em Li (2023).

Cada processo de captura de foto leva cerca de 20 ± 3 s para ser concluído. O *timestamp* (carimbo de data/hora) das fotos deve ser igual ao *timestamp* dos dados de série temporal. Para garantir essa sincronização, é necessário que os *timestamps* das fotos capturadas sempre terminem em zeros. No entanto, devido à incerteza inerente de ± 3 s no horário de captura, foi empregada uma abordagem de arredondamento. Especificamente, o horário da foto foi arredondado para o incremento de 10 s mais próximo. Por exemplo, se o horário real da captura da foto é 1:10:19, ele é arredondado para 1:10:20, de modo que alcance a sincronização com os dados de série temporal.

Além do método de sincronização mencionado, o *script* de captura de fotos incorpora um período de espera antes de capturar a primeira foto. Esse período de espera garante que o *script* comece a capturar fotos no próximo horário agendado que termina em zero. Para as próximas fotos, se o horário de captura não terminar em zero, o *script* aplica o arredondamento citado no parágrafo anterior.


Após a captura, as imagens brutas armazenadas no formato `.h5` são convertidas para o formato `.png` com o comando `h5topng`. Em seguida, as fotos são enviadas para um servidor de armazenamento construído com o MinIO (2023). Assim que a foto chega ao servidor, as imagens brutas passam por um processo de tratamento que as converte em imagens processadas prontas para uso. Esse processo inclui inverter as cores preto e branco, girar a foto para que o norte fique para cima e reduzir o tamanho da foto. Desse modo, as fotos estão prontas para serem usadas pelo SE Preditor de Queda de Geração.

2.2.5 Arquitetura de Comunicação

O cliente Modbus é quem faz a escrita de dados nos equipamentos. Por exemplo, o modo da bateria é alterado de *standby* para carregando pelo cliente Modbus. Porém, quem toma a decisão de quando a bateria deve carregar não é o cliente Modbus, e sim o EMS. Assim, o EMS pode ser programado para armazenar nas baterias a energia produzida em excesso, e descarregar essa energia durante a noite, por exemplo.

Nesse caso, o EMS recebe os dados dos equipamentos, que foram coletados pelo cliente Modbus. Quando necessário escrever dados nos equipamentos, o EMS envia o comando ao cliente Modbus, e o cliente escreve os dados nos equipamentos. Portanto, o cliente (SC Modbus) é quem faz a ponte entre os equipamentos e as aplicações da usina PV/BESS, conforme ilustrado na Fig 7. Entre o cliente e as aplicações pode haver um banco de dados dedicado a armazenar os dados na nuvem, como o InfluxDB, na Fig 7.

Figura 7 – Arquitetura de comunicação do sistema PV/BESS.



Fonte: Autor.

As setas na Fig 7 indicam a direção dos dados. À esquerda, encontram-se os equipamentos. A seta bidirecional indica que o tráfego de dados é bidirecional, ou seja, o cliente tanto lê quanto escreve dados nesses equipamentos (inversor e BESS). Ao centro, os dados de séries temporais são armazenados no banco de dados InfluxDB, e as imagens no MinIO. À direita, encontram-se os sistemas especialistas (SEs), que incluem os preditores e o EMS.

2.3 Resultados e Discussão


Os *softwares*, *frameworks* e protocolos utilizados para construir os dois SCs (Modbus SC e ASC SC) são de código aberto, o que significa que os únicos custos incorridos são com materiais e equipamentos simples, como cabos, um computador e um microcontrolador como o Raspberry Pi.

O padrão IEC 61724 (IEC, 2017) sugere parâmetros a serem coletados em uma usina PVs. Os principais parâmetros foram exibidos na Tabela 1. Esses parâmetros serviram como base para identificar quais deveriam ser medidos na planta experimental desenvolvida. Todos esses parâmetros foram coletados usando os SC Modbus desenvolvido, exceto pela Taxa de Sujidade e Temperatura do módulo PV, para os quais equipamentos adequados não estavam disponíveis. Consequentemente, a planta PV enfrenta limitações no cálculo de certos indicadores de desempenho, como sujidade e perdas de temperatura.

Em IEC (2017), é sugerido o intervalo de amostragem de 3 s. Para demonstrar

a importância dessa taxa de amostragem em plantas PV, na Figura 8 e Tabela 8 são comparadas diferentes taxas de amostragem: 3 s, 10 min e 60 min. Essas três taxas de amostragem foram aplicadas aos mesmo dado (GHI), coletado com o SC Modbus. Na Fig. 8 e Tabela 8, o GHI foi analisado das 04:00 às 18:00 do dia 18 de novembro de 2022, de modo a analisar a variação do GHI , em diferentes amostragens, ao longo de um dia.

Figura 8 – Comparação entre amostragens do mesmo GHI .



Fonte: Autor.

Conforme pode ser observado na Fig. 8, quanto menor a amostragem, maior é a variação do GHI ao longo do dia. Essa variação é mensurada a partir da análise estatística desses dados, apresentada na Tabela 8.

Tabela 8 – Comparação estatística de diferentes amostragens do mesmo GHI .

	3 s	10 min	60 min
Amostras	15625	84	14
Dados ausentes	1175	0	0
Média	373,166	377,354	376,500
Desvio Padrão	364,392	268,302	249,576
Mínimo	0,000	0,000	1,495
Quantil 25%	89,033	112,873	143,506
Quantil 50%	264,154	397,764	432,883
Quantil 75%	506,328	585,475	603,256
Máximo	1407,592	1067,511	710,824
Diferença máxima entre amostras	986,261	624,635	221,706

Fonte: Autor.

Em cada linha da Tabela 8 descreve-se uma informação estatística das amostras, tal como segue:

- Na primeira linha da Tabela 8, é apresentada a quantidade de amostras de cada amostragem. Visto que há 1200 intervalos de 3 s em uma hora, há uma quantidade considerável de dados a mais neste tipo de amostragem. Isso resulta em um

desafio para todas as etapas de trabalho com dados: coleta, pré-processamento, armazenamento e análise dos dados;


- Na segunda linha da Tabela 8, é descrita a quantidade de dados ausentes por amostragem. A porcentagem de dados ausentes da menor amostragem é igual a 7%, enquanto que a das amostragens maiores é igual a 0%. Caso o conjunto de dados amostrados em 3 s seja reamostrado para 10 s, a quantidade de dados ausentes cai para 0%. No entanto, optou-se por apresentar os dados da menor amostragem possível para apresentar a amostra em seu estado original (dado instantâneo), sem ser uma média de duas ou mais amostras;
- Na linha Média, é apresentada a média das amostras, sendo a média de 10 min a maior. No entanto, vê-se que todas médias são próximas, com distância em torno de 1 %;
- Na linha Desvio Padrão, vê-se que o desvio padrão é maior quanto menor a amostragem;
- Nas linhas Quantil 25%, Quantil 50% e Quantil 75% é possível ver que quanto menor a amostragem, os quantis são representados por dados menores;
- Na linha Máximo, pode-se ver que quanto maior a amostragem, menor é o valor máximo, visto que os dados são médias de várias amostras. O valor máximo da amostragem de 3 s é inclusive maior que a irradiância incidente acima da atmosfera, a irradiância extraterrestre, que é em torno de 1367 W/m^2 (DUFFIE, 2020). Isso ocorre devido à concentração de raios solares que acontece em certos momentos, efeito esse conhecido como efeito *Cloud Enhancement* (JARVELA; LAPPALAINEN; VALKEALAHTI, 2020);
- Na linha Diferença Máxima entre Amostras, é apresentado o valor máximo das diferenças entre cada amostra e a amostra anterior. Esta diferença é menor quanto maior é a amostragem.

As Fig. 9, Fig. 10 e Fig. 11 consistem, cada uma, em três subfiguras: (a) *GHI* (W/m^2), (b) foto da ASC e (c) rosa dos ventos, que contém a direção do vento em graus (sentido horário, 0 grau ao norte) e a velocidade do vento (m/s).

É importante observar que a direção do vento é o ângulo de onde o vento está vindo e não para onde está indo. Portanto, se for igual a 45° , significa que o vento está vindo do leste e indo para o oeste. Outra observação a se ter em mente sobre a velocidade e direção do vento é que elas não são medidas na altura das nuvens, portanto não podem ser usadas diretamente para calcular a velocidade das nuvens e o período de sombreamento.

Nas subfiguras (a) da Fig. 9, Fig. 10 e Fig. 11 é apresentado o *GHI* do mesmo período - das 13:00 às 13:15 - e o horário atual é marcado com uma linha vertical laranja. A foto na subfigura (b) foi capturada próximo ao horário da linha laranja. As fotos foram plotadas juntamente com os dados de séries temporais para analisar a sincronização dos dois SCs e para fornecer informações sobre quantos min antes o declínio de potência causado pelo sombreamento pode ser previsto olhando para as fotos do ASC.


Figura 9 – (a) *GHI*, (b) foto da ASC e (c) direção e velocidade do vento.



Fonte: Autor.

Na Fig. 9 são apresentados os dados da estação meteorológica às 13:00:40: *GHI* = 1139,04 W/m^2 , direção do vento = 52,73° e velocidade do vento = 2,28 m/s. A foto do ASC no meio foi capturada às 13:00:43. A foto do ASC mostra um Sol brilhante com uma nuvem à direita - círculo vermelho - que sombreadará o Sol às 13:03:40, fazendo com que o *GHI* caia abruptamente cerca de 75%, causando uma instabilidade na eletricidade exportada pela usina PV.

Figura 10 – (a) *GHI*, (b) foto da ASC e (c) direção e velocidade do vento.




Fonte: Autor.

A Fig. 10 exibe os dados da estação meteorológica às 13:07:00: *GHI* = 270,74 W/m^2 , direção do vento = 113,20° e velocidade do vento = 4,86 m/s. A foto do ASC no

meio foi capturada às 13:07:03. Nesse momento, a nuvem já estava sombreando o Sol por cerca de 5 min.

Figura 11 – (a) GHI , (b) foto da ASC e (c) direção e velocidade do vento.



Fonte: Autor.

Na Fig. 11 são apresentados os dados da estação meteorológica às 13:10:40: $GHI = 267,824 W/m^2$, direção do vento = $56,25^\circ$ e velocidade do vento = $5,13 m/s$. A foto do ASC no meio foi capturada às 13:10:42. O círculo vermelho na foto mostra que o sombreamento vai terminar e o GHI aumentará abruptamente mais de quatro vezes, causando uma instabilidade na eletricidade exportada pela usina fotovoltaica.

2.4 Conclusão

Foram desenvolvidos dois SCs neste trabalho para gerar dados para uma planta PV experimental que utiliza BESS para armazenar energia e uma ASC para prever ocorrências de sombreamento. Esses sistemas de comunicação empregaram exclusivamente *softwares* de código aberto, reduzindo assim o custo total da solução. Além disso, eles podem ser facilmente dimensionados para serem utilizados em usinas PV/BESS de grande porte.

Os dados coletados pelos SCs em usinas PV são descritos e recomendados em normas como a IEC 61724. Neste trabalho, essas recomendações foram seguidas, e a importância da taxa de amostragem de 3 s, como sugerido em (ANSI, 2021), é ilustrada na Fig. 8 e subsequentemente discutida.

Apesar de as normas para dados de plantas PV serem discutidas, atualmente não há um protocolo padronizado para capturar e utilizar fotos da ASC, apesar de sua utilidade em plantas PV que requerem mitigação de quedas abruptas na potência exportada. Portanto, o SC para a ASC foi desenvolvido neste estudo sem um padrão pré-definido. Os resultados deste SC foram explorados nas Fig. 9, Fig. 10 e Fig. 11, permitindo a análise da metodologia adotada ao longo de seu desenvolvimento.

Um dos desafios encontrados no desenvolvimento dos SCs foi sincronizar o *timestamp* das fotografias da ASC com os dados de séries temporais. Isso foi descrito na Seção 2.2.4, e os resultados dessa sincronização foram mostrados nas Fig. 9, Fig. 10 e Fig. 11. Outro desafio foi adaptar a ASC noturna para uma ASC diurna, também detalhada na Seção 2.2.4. Essa adaptação resultou em alguns reflexos nas fotografias da ASC, que podem ser abordados em trabalhos futuros.

Ao comparar as fotografias da ASC com a *GHI* da estação meteorológica, é possível prever quando o sombreamento começará e terminará. Essa capacidade preditiva permite uma operação mais suave do BESS, evitando variações abruptas, como demonstrado na Seção 3.3. Consequentemente, isso pode levar a uma redução na potência necessária e na capacidade mínima do BESS para suavizar a potência gerada.

É importante destacar que o momento da previsão de eventos de sombreamento depende da posição do Sol. Durante o início do dia, a posição do Sol nas imagens está no lado direito, alinhando-se com a direção de onde a normalmente a nuvem vem. Como resultado, quando uma nuvem aparece na imagem no início do dia, ela já está próxima ao Sol, limitando o tempo de previsão. No entanto, após 11:00, o Sol já está longe de onde as nuvens aparecem, permitindo um tempo de espera de 5 min para as previsões de sombreamento serem alcançadas.

Os SCs desenvolvidos neste trabalho desempenham um papel crucial à usina PV experimental, servindo como base para os estudos subsequentes. Através dos SCs, foi possível construir um conjunto de dados, essencial para a realização de trabalhos como análises econômicas e técnicas, além de estudos como a otimização do despacho das baterias, previsão de geração e previsão de queda de geração de energia. Ao viabilizar estas pesquisas, os SCs não apenas contribuem significativamente para a inovação e o desenvolvimento de novos métodos e técnicas em usinas PV/BESS com ASC, mas também impulsionam o avanço da integração eficiente de energias renováveis na matriz elétrica, promovendo assim uma transição energética mais sustentável e confiável.

Referências

- ALI, M. A. et al. *Microgrid Monitoring and Supervision: Web-based SCADA approach*. 2021. Citado na página 31.
- AMMONIT. *Ammonit*. 2023. Disponível em: <<<https://www.ammonit.com/en/products/>>>. Citado na página 35.
- ANSI. Preview of iec 61724-1 ed. 2.0 - photovoltaic system performance-part 1: Monitoring. 2021. Citado 3 vezes nas páginas 10, 30 e 46.
- BIASI, C. et al. Sistema fotovoltaico experimental para pesquisas científicas e sua classificação conforme a iec 61724-1 sistema fotovoltaico experimental para pesquisas científicas e sua classificação conforme a iec 61724-1. 2020. Citado na página 29.
- CHEDDADI, Y. et al. Design and implementation of an intelligent low-cost iot solution for energy monitoring of photovoltaic stations. *SN Applied Sciences*, Springer Nature, v. 2, 7 2020. ISSN 25233971. Citado na página 30.
- DAS, C. K. et al. Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 91, n. March 2018, p. 1205–1230, aug 2018. ISSN 13640321. Disponível em: <<<https://doi.org/10.1016/j.rser.2018.03.068https://linkinghub.elsevier.com/retrieve/pii/S1364032118301606>>>. Citado 2 vezes nas páginas 21 e 28.
- DUFFIE, W. A. B. J. A. *Solar Engineering of Thermal Processes, Photovoltaics and Wind*. 2020. Citado na página 44.
- EVANS, A.; STREZOV, V.; EVANS, T. J. Assessment of utility energy storage options for increased renewable energy penetration. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 16, p. 4141–4147, 2012. ISSN 13640321. Acessado em 10-01-2024. Disponível em: <<<http://dx.doi.org/10.1016/j.rser.2012.03.048>>>. Citado 2 vezes nas páginas 20 e 34.
- HAN, J.; LEE, I.; KIM, S. H. User-friendly monitoring system for residential pv system based on low-cost power line communication. *IEEE Transactions on Consumer Electronics*, v. 61, p. 175–180, 2015. ISSN 00983063. Citado na página 31.

- HUAWEI. Solar inverter modbus interface definitions issue 02. 2021. Acessado em 10-05-2022. Disponível em: <<<https://e.huawei.com>>>. Citado 2 vezes nas páginas 39 e 40.
- IEA. Net zero by 2050: A roadmap for the global energy sector. *International Energy Agency*, p. 224, 2021. Acessado em 10-08-2023. Disponível em: <<<https://www.iea.org/reports/net-zero-by-2050>>>. Citado na página 36.
- IEC. Photovoltaic system performance monitoring-guidelines for measurement, data exchange and analysis - part 1: Monitoring. *Int Stand IEC*, p. 1–10, 2017. Citado 3 vezes nas páginas 29, 30 e 42.
- JARVELA, M.; LAPPALAINEN, K.; VALKEALAHTI, S. Characteristics of the cloud enhancement phenomenon and pv power plants. *Solar Energy*, Elsevier Ltd, v. 196, p. 137–145, 1 2020. ISSN 0038092X. Citado na página 44.
- LI, P.-N. *GitHub - liponan/sxccd-python: Python API for Startlight Xpress CCD (sxccd)*. 2023. Acessado em 07-06-2022. Disponível em: <<<https://github.com/liponan/sxccd-python>>>. Citado na página 40.
- MADETI, S. R.; SINGH, S. N. Monitoring system for photovoltaic plants: A review. *Renewable and Sustainable Energy Reviews*, v. 67, p. 1180–1207, 2017. ISSN 18790690. Citado na página 30.
- MARTIRANO, L. et al. Implementation of scada systems for a real microgrid lab testbed. *2019 IEEE Milan PowerTech, PowerTech 2019*, IEEE, p. 1–6, 2019. Citado na página 31.
- MINIO. *Optimize Snowflake Architecture with MinIO*. 2023. Acessado em 10-05-2022. Disponível em: <<<https://min.io/solutions/>>>. Citado na página 41.
- MODBUS. Modbus application protocol specification v1.1b3 modbus. 2012. Acessado em 10-02-2022. Disponível em: <<<http://www.modbus.org>>>. Citado na página 37.
- NDUKWE, C.; IQBAL, M. T.; KHAN, J. Development of a low-cost lora based scada system for monitoring and supervisory control of small renewable energy generation systems. *11th Annual IEEE Information Technology, Electronics and Mobile Communication Conference, IEMCON 2020*, p. 479–484, 2020. Citado na página 31.
- PYMODBUSTCP. *Welcome to pyModbusTCP's documentation — pyModbusTCP 0.2.0 documentation*. 2023. Acessado em 22-02-2022. Disponível em: <<<https://pymodbustcp.readthedocs.io/en/latest/>>>. Citado na página 38.
- STARLIGHT. *Starlight Xpress Oculus All Sky Camera with 150 Degree Fish Eye Lens / OPT Telescopes*. 2024. Acessado em 20-04-2022. Disponível em: <<<https://>>>.

[//optcorp.com/collections/starlight-xpress/products/sx-oculus-all-sky-camera](http://optcorp.com/collections/starlight-xpress/products/sx-oculus-all-sky-camera)>>.
Citado na página 40.

Capítulo 3

Otimização da Projeção da Potência de um BESS

Resumo

O acoplamento de um BESS a uma usina PV possibilita a essa usina fornecer potência à rede elétrica a qualquer momento, transformando-a em uma usina despachável. Com o objetivo de maximizar os lucros de uma usina PV com BESS, neste trabalho foi desenvolvido um método de otimização da projeção da potência do BESS. A otimização é realizada em janelas deslizantes, permitindo que o algoritmo se adapte às variações dos parâmetros de entrada que ocorrem ao longo do dia, incluindo a previsão de geração de energia. Este método, ao utilizar previsões em janelas deslizantes, possibilita que um erro de desvio padrão de 20% na previsão de geração de energia no início do dia resulte em apenas uma redução de 0,2% no lucro ao final do dia. A função objetivo do problema otimizado inclui funções para evitar a degradação das baterias e para suavizar a curva da potência fornecida à rede elétrica, minimizando a instabilidade causada na rede elétrica devido à intermitência solar. A otimização foi resolvida por um método exato (programação não linear com equações exponenciais e quadráticas) e um método heurístico (algoritmo genético), sendo que o segundo método apresentou resultado 1,99% menor que o primeiro. Com o método exato, o BESS permitiu ganho de 6,94% à usina PV.

Palavras-chaves: otimização, sistema armazenamento de energia em baterias, janela deslizante.

Abstract

The integration of a BESS with a PV power plant enables this plant to supply power to the electrical grid at any time, transforming it into a dispatchable power plant. In this work, a method was developed to optimize the projection of the power of the BESS, with the goal of maximizing the profits of a PV plant coupled with a BESS. The optimization is performed using sliding windows throughout the day, allowing the algorithm to adapt to variations in input parameters that occur along the day, including energy generation forecasts. This method, utilizing sliding window forecasts, enables a 20% standard deviation in the energy generation forecast at the beginning of the day to result in only a 0.2% reduction in profit by the end of the day. The objective function of the optimized problem includes functions to prevent battery degradation and to smooth the power curve supplied to the grid, minimizing instability caused by solar intermittency. The optimization was solved using an exact method (nonlinear programming) and a heuristic method (genetic algorithm), with the latter showing results 1,99% lower than the former. With the exact method, the BESS allowed a 6.94% profit increase for the PV plant.

Keywords: optimizatio, battery energy storage system, sliding windows.

3.1 Introdução

A intermitência da energia solar impede que uma matriz elétrica seja puramente PV. Quando não há irradiância solar, alguma fonte despachável de energia como a termelétrica precisa ser acionada. Outra solução, mais sustentável, é produzir energia PV em excesso quando há irradiância solar, armazená-la em sistemas de armazenamento de energia (ESS), e injetá-la na rede quando não há irradiância.

Os BESS de lítio-ion representam a maior fatia do mercado de ESS (BLOOMBERG, 2022), devido, principalmente, à queda do seu preço nos últimos anos (HANNAN et al., 2021).

A operação do BESS depende de múltiplas variáveis: preço de venda da energia, parâmetros dos equipamentos PV/BESS e da previsão de quanta energia os módulos PV gerarão. Outra dificuldade é que a projeção de qual será a potência de um sistema de baterias ao longo de um período no futuro é de difícil resolução pois há, além da incerteza, uma razão grande entre o número de variáveis e o de equações, aumentando a complexidade do problema.

3.1.1 Revisão da Literatura

Resolver problemas complexos que possuem muitas variáveis através do método bruto é inviável em tempo hábil. Em Jeddi, Mishra e Ledwich (2018) é utilizada programação dinâmica para acelerar a busca pelo melhor resultado do despacho de baterias em um sistema PV/BESS residencial.

Já os métodos heurísticos (MHs) se propõe a achar resultados melhores e em um tempo mais curto em relação à programação dinâmica, pois possuem estratégias mais rebuscadas de busca do melhor resultado. Em Osorio (2023) é feita uma revisão dos MHs mais utilizados para otimizar BESS, de 2019 a 2023. O método mais utilizado foi o Enxame de Partículas (*Particle Swarm Optimization* - PSO), seguido pelo Algoritmo Genético (*Genetic Algorithm* - GA).

O PSO foi proposto pela primeira vez em Eberhart e Kennedy (1995). Essa estratégia de busca é inspirada no comportamento e na dinâmica cooperativista dos movimentos de animais. Um conjunto de soluções é melhorada a cada iteração. Logo, há um ganho da população de melhores soluções. Já no GA, desenvolvido por Holland (1992) desde 1965, a estratégia é inspirada na rivalidade entre indivíduos. As soluções não interagem e há um ganho individual da melhor solução.

Calloquispe-Huallpa et al. (2023) compararam a otimização feita com PSO e GA do despacho econômico de um *microgrid* contendo uma carga e três sistemas PV/BESS

Tabela 9 – Quantidade de MHs e MXs utilizados na otimização de BESS, na revisão feita por Osorio (2023).

Classificação	Quantidade de artigos	Quantidade de métodos
MX	31	4
MH	103	23
Total	134	27

Fonte: Adaptado de Osorio (2023).

com diferentes potências, capacidades e tempo estimado de vida. útil. Foi utilizada a amostragem de 15 min para cada intervalo de otimização. Argumentam que o problema de despacho econômico de *microgrids* possui muitas descontinuidades, tornando a resolução do problema via MXs difícil, e portanto recomendam o uso de MHs. Comparam os resultados dos PSO e GA e concluem que são semelhantes, sendo o resultado do PSO melhor, além de apresentar menor tempo de execução.

Nos MHs, diferentes soluções são encontradas a cada execução do algoritmo. Portanto, é recomendado executar o algoritmo diversas vezes e comparar os seus resultados, de modo a analisar a proximidade entre eles. MHs apresentam a vantagem, em relação aos métodos exatos (MXs) de otimização, de tratar o problema como se fosse uma caixa preta. Isso ocorre pois o *script* de otimização meta-heurístico não precisa conhecer o problema a ser resolvido, enquanto o MX precisa que o problema a ser otimizado seja modelado em algum ambiente algebraico de modelagem exata como o Pyomo (2023) em Python e o GAMS (2023). Logo, os MHs podem otimizar problemas modelados em programas especialistas no problema, externos ao programa onde o *script* heurístico de otimização está modelado.

Um programa especialista em problemas de fluxo de potência é o OpenDSS (2023), utilizado também para modelar a inserção de BESS em redes elétricas de forma a diminuir a sua instabilidade. Em Lopes et al. (2020) foi utilizado GA desenvolvido em Python para otimizar a alocação do BESS em sistemas elétricos com grande penetração de sistemas PV, de forma a minimizar os custo associado à alocação do banco de baterias, e minimizar as transgressões de desvio de tensão. O GA faz o cruzamento dos indivíduos que obtiveram os melhores resultados em cada iteração e os envia ao OpenDSS, que calcula o resultado dos indivíduos da nova geração. Após, o OpenDSS envia esses resultados de volta ao GA, que cruza os indivíduos e os reenvia ao OpenDSS. Esse fluxo entre o GA em Python e o OpenDSS acontece até que o critério de parada seja atingido, que é parar de encontrar um resultado melhor.

Al-Maaitah e Al-Majali (2021) utilizaram um fluxo de resolução de problemas semelhante ao trabalho supracitado. Desenvolveram uma modelagem de BESS em Matlab/-Simulink e otimizaram a sua alocação no sistema de distribuição IEEE de 9 barras. Citam

que os MHs apresentam melhor performance do que MXs quando resolvem problemas que incluem modelagens complexas, como a do sistema de 9 barras. No entanto, o fato de a modelagem não ter sido realizada em um ambiente de otimização exata impossibilita a resolução por MXs.

A necessidade dos MXs de terem o problema modelado em ambiente específico de modelagem exata é a desvantagem deles em relação aos MHs. O uso de programas especialistas, externos, é impossibilitado. Porém, essa desvantagem é minimizada quando a vantagem dos MXs em relação aos MHs é considerada: os MXs garantem que o melhor resultado seja sempre encontrado.

Os MXs são classificados de acordo com o tipo do espaço de busca do problema: linear, não linear, inteiro, entre outros. Apresentam a desvantagem de precisar ter acesso a todas equações e parâmetros de entrada do problema, de forma que o programa resolvidor do problema (*solver*) consiga desenhar todo o espaço de busca. Isso torna a modelagem mais difícil de ser realizada. Programas especialistas no problema, como o OpenDSS (2023) para o caso de problemas de fluxo de potência, não podem ser usados.

Modelagens de BESS em ambientes de otimização exata são descritas em poucos trabalhos na literatura, e quando descritas, são modelagens simplificadas. Em Soroudi (2017) e em Soroudi (2023), o lucro do despacho diário de um BESS inserido em uma rede elétrica inteligente com inserção de fontes renováveis é maximizado em ambiente GAMS. De modo semelhante, em Montoya, Gil-González e Grisales-Noreña (2020) a alocação de um BESS é otimizada em ambiente GAMS com o objetivo de minimizar a emissão de gases do efeito estufa. Já em Barbour e González (2018), um sistema PV/BESS residencial é otimizado em ambiente Pyomo, de forma a minimizar a conta de luz.

Na literatura recente foram desenvolvidas modelagens complexas de BESS, tendo em vista, principalmente, a modelagem da degradação da bateria. Desta maneira, o uso da bateria pode ser otimizado visando não obter o maior lucro imediato, mas sim o melhor lucro imediato que permita um maior lucro total ao longo da vida útil dos equipamentos. Zia, Elbouchikhi e Benbouzid (2019) utilizam funções de custo relacionadas à degradação da bateria de modo a aumentar a vida útil da mesma.

No entanto, essas modelagens complexas de BESS, que incluem a modelagem de sua degradação, não são encontradas em ambientes de otimização exata na literatura.

Neste trabalho, foi realizada uma pesquisa do estado da arte de modelagem de baterias de lítio-ion e estas equações foram modeladas no ambiente de modelagem exata Pyomo. Após, foi desenvolvido um método de projeção da potência da bateria que servirá de *set point* para um BESS. Essa projeção é otimizada com programação não linear com equações quadráticas e exponenciais, de modo que a projeção ótima seja encontrada.

Visto que há, muitas vezes, diferentes operações que resultem no lucro máximo,

foram adicionadas à função objetivo duas funções de custo que visam achar, dentro dessas operações de lucro maximizado, qual é a operação que reduz menos a vida útil das baterias.

De forma semelhante, dentro das operações de lucro maximizado, há operações que fornecem uma potência à rede elétrica mais suave, sem variações abruptas de potência. Portanto, foi adicionado uma função de custo para maximizar a suavização da potência fornecida à rede elétrica.

A projeção foi desenvolvida e aplicada de modo a emular uma usina PV centralizada que comercializa energia elétrica. Para tanto, foi utilizada a usina PV/BESS descrita na Seção 2.2.1.

Considerou-se a forma de comercialização de energia do Ambiente de Contratação Regulado (ACR). Neste ambiente, segundo a CCEE (2022), os contratos são celebrados através de leilões entre as distribuidoras de energia elétrica e as unidades geradoras, existindo duas alternativas: contrato por disponibilidade ou contrato por geração de energia. Neste último, as responsabilidades relativas a ultrapassagem entre a energia gerada no Mercado de Curto Prazo (MCP), seja pra mais ou para menos, e o valor determinado por contrato de venda recaem sobre o vendedor (geradora).

3.1.2 Objetivo Geral

O objetivo geral deste capítulo é maximizar o lucro que um BESS gera em uma usina PV/BESS.

3.1.3 Objetivos Específicos

- Achar o *set point* do P_{BESS} que gere o maior lucro em uma usina PV/BESS;
- Comparar o resultado otimizado pelo MX com o do MH.
- Desenvolver funções de custo que aumentem a vida útil da bateria, sem reduzir o lucro.
- Analisar a influência da incerteza da previsão de PV na projeção de PV/BESS;
- Inserir função de custo que suavize a potência fornecida à rede elétrica, sem reduzir o lucro, de forma a fornecer uma energia de maior qualidade à rede elétrica.

3.1.4 Contribuições

- Resolver as equações exponenciais e quadráticas do estado da arte da modelagem de baterias em modelagem exata, de modo que o melhor resultado seja encontrado.

- Desenvolver uma otimização que não só maximize o lucro, mas também diminua o mínimo possível a vida útil das baterias e forneça uma potência de maior qualidade à rede elétrica, com menos variações abruptas.

3.1.5 Delimitações do Trabalho

Um dos principais parâmetros de entrada da modelagem da projeção de P_{BESS} é a previsão de quanta energia será gerada. No entanto, o desenvolvimento e a descrição de como essa previsão é feita não é o objetivo deste trabalho. Foi utilizada uma simulação desta previsão.

3.2 Metodologia

A modelagem de um sistema tem como objetivo descrever o seu comportamento em relação às variações dos seus parâmetros de entrada. O sistema, no caso deste trabalho, é uma usina PV/BESS construída com objetivos experimentais, sendo o objetivo do experimento deste capítulo a otimização do lucro de venda de energia. Portanto, a modelagem do sistema inclui os equipamentos da usina PV/BESS, e os parâmetros e regras de comercialização de energia.

Os parâmetros da usina PV/BESS utilizados na modelagem são os da usina PV/BESS de 10 kWp instalada no CEAR/UFPB, descrita na Seção 2.2.1. Os dados foram coletados a partir do SC que teve o seu desenvolvimento descrito na Seção 2.2.3.

A usina instalada, de pequeno porte, tem o objetivo de emular a integração de BESS em usinas PV de grande porte, mais especificamente, uma das usinas PV do Complexo Solar de Coremas na Paraíba, Brasil. Portanto, o sistema de precificação modelado é o utilizado por usinas centralizadas de energia renovável. A precificação, regulada pela ANEEL e aplicada pela CCEE, é utilizada por usinas de energia renovável conectadas no SIN. Essa precificação é descrita na Seção 3.2.2.

Antes disso, é apresentado a seguir os algoritmos que foram utilizados para obter o resultado otimizado, que incluem um algoritmo de MX e o GA, representando os MHs.

3.2.1 Algoritmos de otimização

O objetivo da otimização desenvolvida é maximizar o lucro do despacho econômico da usina PV/BESS. Conforme os algoritmos relacionados ao BESS evoluem e a sua complexidade aumenta, é comum serem resolvidos por MHs, visto que são mais simples de serem modelados, são rápidos e encontram soluções boas, ao invés dos MXs, que possuem

modelagem mais difícil, mas por sua vez garantem encontrar o melhor resultado. Não é comum encontrar na literatura modelagens complexas de BESS resolvidas por MXs.

Neste trabalho é proposto realizar a comparação do resultado otimizado em função do tempo de execução, calculado a partir de um MH e de um MX. As equações e parâmetros modelados são iguais para os dois métodos, e são descritos mais a frente. As particularidades dos dois métodos se resumem a como encontram a melhor solução.

Foi utilizado o ambiente de desenvolvimento VS Code tanto para a modelagem do GA como a do MX, e o tempo de execução dos dois algoritmos é comparado mais a frente.

3.2.1.1 Método Heurístico

Para representar os MHs, o problema foi resolvido a partir do GA, desenvolvido com o *framework* DEAP (RAINVILLE et al., 2012) em Python.

O GA é inspirado na teoria evolucionista que explica a origem das espécies (KONAK; COIT; SMITH, 2006). A seguir, é feita uma breve descrição da teoria da origem das espécies, comparando os seus termos com os termos utilizados no GA.

Na natureza, indivíduos fracos ou inadequados dentro de seu ambiente acabam não passando seus genes para as próximas gerações (iterações, no GA). Os mais fortes têm uma maior oportunidade de passar seus genes para as gerações futuras através da reprodução (cruzamento, no GA).

A longo prazo, espécies que carregam a combinação correta em seus genes (melhor resultado, no GA) tornam-se dominantes em sua população (elitismo, no GA). Às vezes, durante o processo lento de evolução, podem ocorrer mudanças aleatórias nos genes (mutação, no GA). Se essas mudanças fornecerem vantagens adicionais no desafio para a sobrevivência, novas espécies evoluem das antigas. Mudanças mal sucedidas são eliminadas pela seleção natural. Os parâmetros inspirados na teoria evolutiva e os seus valores utilizados no GA são descritos a seguir:

- População: conjunto de indivíduos que vão realizar cruzamento genético. Foi utilizada uma população de 20 indivíduos.
- Indivíduo: Conjunto de genes. Cada indivíduo possui 144 genes (144 P_{BESS} , das 00h00 às 23h50 de um dia).
- Gene: P_{BESS} específico de algum horário.

A cada iteração do algoritmo, os indivíduos da população sofrem uma das três intervenções descritas a seguir:

- Cruzamento: 25% dos indivíduos trocam genes.
- Elitismo: Os 50% de indivíduos que geram os melhores resultados são mantidos sem modificações para as próximas gerações (iterações).
- Mutação: 25% dos indivíduos tem seus genes alterados aleatoriamente. Foi configurado para 12 genes mudarem por indivíduo mutado a cada iteração.

O primeiro resultado calculado com o GA, ou seja, o resultado da primeira população (primeira iteração), é realizado a partir de indivíduos de genes (P_{BESS}) aleatórios. Cada P_{BESS} está dentro do conjunto dos reais, visto que P_{BESS} pode assumir valores *float* positivos (descarregamento do BESS), negativos (carregamento do BESS), ou mesmo o valor zero (*standby*, ou em espera), mas sempre dentro dos limites -5 e 5. Visto que há milhões de soluções a ser analisadas, dificilmente um P_{BESS} aleatório gerará um bom resultado.

Para tornar o GA mais eficiente, foi selecionado como conjunto dos genes de cada indivíduo o conjunto dos números inteiros. Desse modo, cada P_{BESS} inicial aleatório pode ter 11 valores diferentes (de -5 a 5, 0 incluso). E caso um P_{BESS} seja grande demais de forma que o valor de SOC máximo seja ultrapassado, esse P_{BESS} é limitado ao valor que não faça com que o SOC máximo seja ultrapassado. Logo, por mais que seu valor inicial seja um número inteiro, no meio do algoritmo ele é limitado e acaba se tornando um valor *float*.

3.2.1.2 Método Exato

Para a resolução do problema via MX, foi utilizado o *framework* Pyomo.

Devido ao problema modelado possuir equações não lineares, é necessário selecionar algum *solver* de otimização não linear. Foram testados alguns dos *solvers* disponíveis em Coinor (2024). Visto que na modelagem há equações exponenciais, alguns *solvers* tem dificuldade em resolver o problema de maneira rápida. Foi selecionado o *solver* Ipopt para resolver o problema proposto, visto que este obteve o melhor desempenho em questão de tempo de execução.

3.2.1.3 Comparação das características dos MHs e MXs.

Na Tabela 10 são apresentadas de forma resumida algumas características dos MHs e MXs. Após a Tabela 10 estas características são descritas e comparadas.

Tabela 10 – Comparação entre MHs e MXs.

	MHs	MXs
Resultado	- Acha bons resultados	Acha o melhor resultado
Paradigma	- Caixa preta	Caixa branca
Desenvolvimento	- Fácil	Criterioso
Hiperparametrização	- Requer	Não requer
Escolha do método	- Difícil	Simples
Ambiente e linguagem	- Muitos	Poucos

Fonte: Autor.

- Resultado: Os MHs têm a capacidade de encontrar resultados satisfatórios para problemas complexos, embora não garantam a solução ótima. Por outro lado, os MXs, que possuem natureza determinística, sempre alcançam a melhor solução possível, desde que seja computacionalmente viável.
- Paradigma do problema: Os MHs não precisam conhecer o problema que será resolvido, ou seja, o problema pode ser modelado de acordo com o paradigma conhecido como caixa preta. Já os MXs exigem que o problema seja descrito detalhadamente (caixa branca).
- Facilidade de desenvolvimento: Os MHs não possuem sintaxe rigorosa, sendo possível modelar o problema de diversas maneiras, ou seja, os MHs são flexíveis. Por outro lado, os MXs possuem regras mais rigorosas de sintaxe.
- Hiperparametrização: Os MHs possuem e os MXs não possuem hiperparametrização. No caso dos MXs, o foco do desenvolvimento fica somente no problema em si. Já no caso dos MHs, é necessário que uma boa parte do tempo de desenvolvimento seja dedicada à hiperparametrização. No caso do MH GA, exemplos de hiperparâmetros que demandam tempo de desenvolvimento são a quantidade de indivíduos por população, quantidade de gerações, tipos de cruzamento, elitismo e mutação, proporções da população que sofrerá cada tipo de intervenção, entre outros parâmetros.
- Escolha do método utilizado: ao se utilizar um MH, é necessário fazer a escolha de qual MH será utilizado (PSO, GA, entre muitos outros). As vezes é necessário testar a resolução do problema modelado com mais de um MH, de forma a determinar qual MH lida melhor com o problema modelado. Já quando o problema é resolvido por um MX, não requer modelagem de diferentes tipos de MXs. A modelagem dos MXs é sempre igual, independentemente se o problema é linear, não linear, quadrático, misto, etc. Em relação à qual *solver* utilizar, o próprio ambiente de desenvolvimento (Pyomo) indica qual precisa ser utilizado.
- Ambiente e linguagem de desenvolvimento: Enquanto os MHs permitem uma escolha livre de ambiente de desenvolvimento e linguagem de programação, oferecendo flexi-

bilidade aos desenvolvedores, os MXs são mais restritivos nesse aspecto, dependendo de implementações específicas para funcionar corretamente.

3.2.2 Precificação de energia do SIN

Os geradores de energia como a usina PV Coremas vendem sua energia elétrica para as distribuidoras por meio de contratos de longo prazo, estabelecidos em leilões regulados pela ANEEL (CCEE2,). Esses contratos garantem uma parte da receita dos geradores, sendo esta parte estável e previsível.

O contrato de venda de energia do gerador contém a quantidade de energia que ele deve ter disponível (energia contratada E_{CONT} , em kWh) e o preço que ele recebe pela disponibilidade dessa energia (valor do contrato V_{CONT} , em R\$/kWh). Logo, o lucro da usina originado a partir do mercado regulado (L_{MR}), em R\$, é calculado com a Eq 3.1.

$$L_{MR} = E_{CONT} \cdot V_{CONT} \quad (3.1)$$

No entanto, os geradores possuem uma incerteza em relação à sua receita devido ao excedente da geração ser valorado de acordo com MCP. Dito de outra forma, o gerador é exposto ao MCP. O MCP é composto pela variação do Preço Líquido das Diferenças (PLD , em R\$/kWh), sendo o PLD o preço do kWh à qual o gerador é exposto. O PLD varia a cada hora ANEEL (CCEE2,). Para calcular o lucro ou despesa do gerador frente ao MCP é utilizada a Eq 3.2,

$$L_{MCP} = (E_m - E_{CONT}) \cdot PLD \quad (3.2)$$


onde E_m , em kWh, representa a energia que o gerador forneceu à rede elétrica. E_m é igual a potência vezes a quantidade de horas de fornecimento desta potência, conforme a Eq. 3.3.

$$E_m = P_{PV} \cdot horas \quad (3.3)$$

Quando $E_m > E_{CONT}$, o gerador lucra, e quando $E_m < E_{CONT}$, o gerador tem prejuízo perante ao MCP. Logo, o lucro diário da usina é calculado pela soma do lucro estável (L_{MR}) e o lucro flutuante (L_{MCP}), representado por L_{TOTAL} .

$$L_{TOTAL} = L_{MR} + L_{MCP} \quad (3.4)$$

É apresentado na Fig. 12 os $PLDs$ de maio de 2018 a janeiro de 2024, obtidos em CCEE (2022).

Figura 12 – Perfil do *PLD* do submercado Nordeste ao longo dos últimos anos.


Fonte: Autor.

Conforme pode-se ver na Fig. 12, o *PLD* sofreu variações ao longo dos meses, até o ano 2021. Já em 2022, o *PLD* ficou estável em R\$/MWh 55,70 ao longo do ano, com exceção ao mês de Julho e Agosto, atingindo o valor máximo de de R\$ 130,73 no dia 3 de Agosto de 2022.

Em 2023, o *PLD* também continuou estável, porém agora no valor de R\$/MWh 69,04. No final do ano de 2023 houveram alguns momentos nos quais o *PLD* teve grandes aumentos, chegando a R\$/MWh 620,95 durante a noite de 28 de setembro de 2023. No entanto estes aumentos ocorreram com duração de poucas horas por dia, e logo voltaram ao preço padrão.

De forma a exemplificar a variação do *PLD* ao longo de um dia, é apresentada na Fig. 13 a variação do *PLD* ao longo do dia 18 de novembro de 2023. Este dia foi usado de exemplo para apresentar alguns dos resultados deste trabalho.

Figura 13 – Variação do PLD do submercado Nordeste ao longo do dia 18 de novembro de 2023.



Fonte: Autor.

3.2.3 Simulação e Previsão de P_{PV}

A previsão de algum parâmetro normalmente é feita a partir da análise do comportamento deste parâmetro no passado. Portanto, para prever P_{PV} , o ideal seria realizar esta previsão a partir do próprio P_{PV} coletado por um período longo o suficiente. No entanto, em uma usina sendo implementada, dificilmente tem-se dados suficientes para se realizar a previsão de P_{PV} .

Logo, em sistemas especialistas que fazem a previsão de P_{PV} , é comum se coletar o GHI histórico disponibilizado por institutos meteorológicos como o INMET (2024) e realizar a previsão de GHI . E a partir desse GHI previsto, simular o P_{PV} previsto.

Para a utilização no algoritmo de otimização desenvolvido neste trabalho, o P_{PV} foi simulado a partir do GHI coletado na estação meteorológica, devido ao motivo acima exposto, e a um segundo motivo, exposto abaixo.

O conjunto de dados formado a partir da coleta de dados que utilizou o SC descrito na Seção 2.2.3, possui uma quantidade significativa de dados de potência (P_{PV}) ausentes, devido a problemas técnicos nos equipamentos (PV). Em contrapartida, quase não há ausência de dados da estação meteorológica. De modo a obter uma quantidade maior de dados P_{PV} , foi realizada uma simulação dos valores de P_{PV} a partir do GHI . Para tanto, utilizou-se o *framework* de modelagem PV PVLlib em Python.

3.2.3.1 Simulação de P_{PV}

A simulação dos módulos (PV), realizada no **PVLib**, segue a modelagem desenvolvida por Soto, Klein e Beckman (2006), conhecida como modelo de um diodo ou modelo dos cinco parâmetros. Na Tabela 11, são apresentados os parâmetros do módulo PV utilizado na usina experimental PV/BESS, conforme descrito na Seção 2.2.1.

Tabela 11 – Parâmetros do módulo PV JINKO JKM530M-72HL4-TV, utilizado na usina experimental PV/BESS.

Parâmetro	Valor	Unidade
Área	2,574	m ²
Número de células em série	72	-
Corrente de curto-circuito de referência	13,71	A
Tensão de circuito aberto de referência	49,35	V
Corrente de ponto de máxima potência de referência	13,02	A
Tensão de ponto de máxima potência de referência	40,71	V
Coefficiente de temperatura de corrente de curto-circuito	0,00659	A/°C
Coefficiente de temperatura de tensão de circuito aberto	-0,13818	V/°C
Quantidade de módulos PVs	19	-

Fonte: Autor.

Para modelar o módulo PV em **PVlib**, é necessário, de forma adicional aos parâmetros da Tabela 11, estimar a temperatura média das células PVs (T_{CEL}). Para tanto, T_{CEL} foi estimada usando o modelo de T_{CEL} desenvolvido por Ross (1986), que utiliza a Eq. 3.5,


$$T_{cel} = T_{ar} + R \cdot GHI \quad (3.5)$$

onde R é o coeficiente de ROSS. O R foi estimado a partir de um método iterativo, começando a partir de $R = 0,01$, e incrementando R em 0,01 a cada nova iteração. A cada iteração, o erro foi calculado com a Eq. 3.6.

$$erro = |P_{PV,CALC} - P_{PV,REAL}| \quad (3.6)$$

O menor erro foi encontrado para $R = 0,08$.

Na Fig. 14 são apresentadas algumas amostras do P_{PV} medido no inversor ($P_{PV,REAL}$) e do P_{PV} simulado com o **PVlib** ($P_{PV,CALC}$).

Figura 14 – Comparação entre o 1400 amostras do $P_{PV,REAL}$ e $P_{PV,CALC}$.

Fonte: Autor.

Logo, no restante deste capítulo a potência fotovoltaica calculada $P_{PV,CALC}$ foi utilizada para o restante da modelagem, e portando, ela é referida simplesmente como P_{PV} .

3.2.3.2 Simulação da Previsão de P_{PV}

Trabalhos relacionados ao despacho de baterias em usinas PV/BESS geralmente consideram a previsão de P_{PV} como se fosse perfeita. Ou seja, é considerado que o gerenciador de energia já sabe qual a energia que será gerada pelos módulos PV com antecedência.

Visando contribuir com esse assunto, neste trabalho o erro da previsão foi simulado. A previsão modelada é feita várias vezes ao longo do dia. Conforme o andamento do dia, vai se coletando mais informações meteorológicas e portanto, vai se fazendo novas previsões de menor erro.

Apesar de a previsão de P_{PV} não ter sido desenvolvida neste trabalho, julgou-se importante simulá-la visando estudar o impacto desta incerteza no lucro real gerado ao final do dia, ao invés de estimar o máximo lucro possível extraído caso a previsão fosse idealizada (sem erros).

Pra simular o erro da previsão, foi aplicado ao P_{PV} coletado um erro de distribuição gaussina (distribuição normal). Logo, o P_{PV} previsto ($P_{PV,fut}$) é calculado com a Eq. 3.7,


$$P_{PV,fut} = P_{PV} + \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(\mu)^2}{2\sigma^2}}, \quad (3.7)$$

onde μ é a média da distribuição e σ é o desvio padrão. Foram adotados os seguintes valores para as previsões:

- $\sigma = 0,2$ para a previsão amostrada em 60 min;
- $\sigma = 0,05$ para a previsão amostrada em 10 min.

É mostrado na Fig. 15 a diferença entre o P_{PV} amostrado em 60 min e o $P_{PV,fut}$, simulado a partir da Eq. 3.7. Os dados são do dia da Fig. 13, 18 de novembro de 2023. É válido ressaltar que a distribuição normal aplicada é aleatória, e portanto o $P_{PV,fut}$ é diferente a cada nova previsão, ou seja, a Fig. 15 é o exemplo de uma só previsão feita.


Figura 15 – Comparação entre o P_{PV} e o P_{PV} com erro imbutido, amostrados em 60 min, de forma a simular a previsão de $P_{PV,fut}$.



Fonte: Autor.

Já na Fig. 16, é apresentado o P_{PV} amostrado em 10 min, em comparação com o $P_{PV,fut}$ simulado a partir da Eq. 3.7. É possível visualizar que o $\sigma = 0,05$ aplicado no $P_{PV,fut}$ da Fig. 16 faz com que este $P_{PV,fut}$ seja mais próximo ao P_{PV} real, quando comparado com o $P_{PV,fut}$ da Fig. 15, que foi calculado com $\sigma = 0,2$.

Figura 16 – Comparação entre o P_{PV} e o P_{PV} com erro imbutido, amostrados em 10 min, de forma a simular a previsão de $P_{PV,fut}$.



Fonte: Autor.

No começo de cada dia, a previsão é semelhante à da Fig. 15. No entanto, conforme o dia vai andando, são feitas novas previsões a cada 10 min, semelhantes à da Fig. 16. É desejado que este método de previsões em janelas deslizantes, ao longo do dia, faça com que o impacto da incerteza da previsão seja diminuído. O resultado deste impacto é mostrado na Seção 3.3.5.

3.2.4 Estrutura do script de otimização

Independentemente de o problema ser otimizado por um MH ou por um MX, a modelagem do problema segue uma estrutura predefinida, que inclui:

- Função objetivo: descreve qual a variável que será maximizada ou minimizada;
- Variáveis de decisão: são as variáveis calculadas pela modelagem que são entradas da função objetivo;
- Parâmetros de entrada: são os parâmetros que servem de entrada para a modelagem, como por exemplo o estado dos equipamentos e as previsões de geração de energia;
- Restrições: incluem as equações que estabelecem as relações entre as variáveis de decisão e os parâmetros de entrada;

3.2.4.1 Função Objetivo

A função objetivo da modelagem realizada (Eq. 3.8) maximiza a variável $F_{OBJETIVO}$, em R\$, para determinadas variáveis de decisão VD,

$$\max_{VD} F_{OBJETIVO} = \sum_t^T (L_{TOTAL,t} - C_{DOD,t} - C_{CA,t} - C_{SUAV,t}) \quad (3.8)$$

onde $F_{OBJETIVO}$ é igual ao somatório do lucro e custos de cada passo t ao longo do período de otimização T . Neste somatório estão inclusos o lucro de venda de energia L_{TOTAL} , já apresentado anteriormente (Eq. 3.4), e os custos, que serão detalhados à frente. Estes custos incluem o custo de degradação das baterias atribuído ao uso (C_{DOD}), o custo atribuído ao envelhecimento da bateria caso ela não seja utilizada (C_{CA}) e o custo de suavização (C_{SUAV}) da potência fornecida à rede elétrica.

É válido ressaltar que os custos C_{DOD} , C_{CA} e C_{SUAV} são fictícios, ou seja, não reduzem o valor real arrecadado da venda de energia da usina PV/BESS diariamente, que é calculado por somente $\sum_{t=0h}^{24h} L_{TOTAL}$. No entanto, a inserção dos custos C_{DOD} e C_{CA} faz com que o somatório de lucros da usina ao longo da vida útil das baterias seja maximizado. Caso C_{DOD} e C_{CA} sejam retirados da Eq. 3.8, a degradação da bateria será desconsiderada e o BESS será operado de maneira que terá a sua vida útil reduzida.

Logo, com a inserção de C_{DOD} e C_{CA} na função objetivo da Eq. 3.8, a otimização acha não somente o resultado que dê o maior lucro diário, mas sim o melhor lucro diário que permita um maior lucro total ao longo da vida útil dos equipamentos, visto que a vida útil destes será prolongada.

Já o terceiro custo, C_{SUAV} , visa suavizar a curva de P_G , de modo a não fornecer mudanças abruptas de P_G e causar instabilidade na rede elétrica. Desse modo, não só a usina PV é beneficiada pelo uso do BESS, mas toda a rede elétrica e seus usuários.

3.2.4.2 Variáveis de Decisão

As VDs são parâmetros calculados. Deseja-se achar seus valores ideais que permitam que a função objetivo seja maximizada. A Tabela 12 apresenta as VDs da otimização da projeção de P_{BESS} e seus limites inferior e superior.

Tabela 12 – Variáveis de decisão e seus limites.

Descrição	Símbolo	Limite inferior	Limite superior	Unidade
Lucro de venda de energia	$L_{TOTAL,t}$	-	-	R\$
Custo de degradação devido ao uso	$C_{DOD,t}$	-	-	R\$
Custo de degradação devido ao não uso	$C_{CA,t}$	-	-	R\$
Custo de suavização de P_G	$C_{SUAV,t}$	-	-	R\$
Estado de Carga	SOC_t	2	10	kWh
Profundidade de descarga	DOD_t	0	8	kWh
DOD médio	DOD_{AVG}	-	-	kWh
Potência da bateria	$P_{BESS,t}$	-5	5	kW
Potência fornecida à rede elétrica	$P_{G,t}$	0	5,5	kW
Energia usada no ciclo atual	$E_{t,t}$	-	-	kWh
Energia total utilizável	E_T	-	-	kWh
Energia medida	$E_{m,t}$	0	10	kWh

Fonte: Autor.

Cada passo é representado por t , e os parâmetros que possuem o subscrito t são calculados a cada passo. Já os parâmetros que não tem o subscrito t , são calculados uma vez só para cada período T otimizado.

As quatro primeiras VDs da Tabela 12 são os lucros e custos, já descritos após serem mencionados na Eq. 3.8. O restante das VDs é descrito a seguir.

SOC_t , em kWh, representa a quantidade de energia armazenada nas baterias dentro do BESS. Os fabricantes informam que caso as baterias não descarreguem totalmente, a bateria perde menos capacidade de armazenamento com o passar do tempo. Os limites de SOC são iguais aos utilizados em Mohamed et al. (2022), limite inferior igual a 20% e limite superior igual a 100%, sendo estes iguais a 2kWh e 10kh para um BESS de 10 kWh.

DOD_t , em kWh, é a profundidade de descarga do BESS. É o inverso do SOC_t . Logo, o DOD_t máximo é de 8 kWh.

DOD_{AVG} , em kWh, é a média das profundidades de descarga ao longo de um dia.

$P_{BESS,t}$, em kW, é a potência do BESS. Ela é positiva quando as baterias estão fornecendo energia à rede elétrica, e negativa quando estão carregando energia recebida dos módulos PV.

$P_{G,t}$, em kW, é a potência fornecida à rede elétrica. O limite inferior de $P_{G,t}$ é igual a 0, ou seja, a rede elétrica não fornece potência ao BESS. É comum ser estabelecido em contrato o limite máximo de $P_{G,t}$, que normalmente é relacionado aos limites físicos do sistema de distribuição elétrica ao qual a usina está conectada. Neste trabalho, foi utilizado o limite 5,5 kW, que é a potência máxima que o inversor utilizado na usina PV/BESS modelada possui.

$E_{t,t}$, em kWh, é a energia do BESS utilizada em cada passo t .

E_T , em kWh, é a energia total prevista que será utilizada durante a vida útil do BESS.

3.2.4.3 Parâmetros de Entrada

O *script* de otimização possui como entrada parâmetros fixos (Tabela 13) e parâmetros variáveis (Tabela 14). Os parâmetros fixos são iguais durante o período T que está sendo otimizado, porém podem ou não variar de um período para outro período. Após a Tabela 13, essa variação é descrita com mais detalhes.

Os parâmetros de entrada são definidos nesta seção, e após, a relação entre eles e as VDs é equacionada na Seção 3.2.4.4.

Tabela 13 – Parâmetros fixos de entrada.

Origem	Descrição	Símbolo	Valor	Unidade
Inversor	Eficiência do inversor	$\eta_{inversão}$	0,9	-
	Eficiência da rede elétrica	η_{GRID}	0,98	-
	Potência de contrato	P_{lim}	5,5	kW
	Capacidade do BESS	Q	10	kWh
	Estado de carga inicial	SOC_0	2	kWh
	Eficiência de Carregamento	η_{carga}	0,95	-
	Eficiência de Descarregamento	$\eta_{descarga}$	0,95	-
Precificação	Capacidade no fim de vida	EOF	0,2	-
	Energia Contratada	E_{CONT}	1,5	kWh
	Valor Contratado	V_{CONT}	0,18	R\$/kWh
	Custo de compra do BESS	C_{BESS}	6679,20	R\$

Fonte: Autor.

A seguir os parâmetros fixos de entrada, apresentados na Tabela 13, são descritos.

- $\eta_{inversão}$ é a eficiência de inversão do inversor, de potência elétrica contínua para potência elétrica alternada. É constante para todos períodos T ;
- η_{GRID} é a eficiência de transporte de P_G , do inversor até o local de fornecimento de P_G à rede elétrica.
- P_{lim} , em kW, é o limite superior de P_G . Caso a usina forneça à rede elétrica potência maior que essa, ela é penalizada. Portanto, esta potência é fixada para todos os períodos T , enquanto o contrato for mantido.
- Q , em kW, é a capacidade de armazenamento de energia do BESS.
- SOC_0 , em kWh, é o estado de carga inicial do período a ser otimizado. Varia a cada período de otimização. O SOC_0 de um período é igual ao SOC final do período anterior, SOC_{-1} ;

- η_{carga} é a eficiência de carregamento das baterias, constante para todos períodos;
- $\eta_{descarga}$ é a eficiência de descarregamento das baterias, constante para todos períodos;
- EOF , em kWh, é a capacidade de armazenamento do BESS quando ele não é mais considerado útil. Esse valor é constante para todos períodos.
- E_{CONT} , em kWh, é a quantidade de energia que deve ser fornecida a cada hora, determinada em contrato. É utilizada na Eq. 3.1 de modo que L_{MR} seja calculado. Há contratos de usinas que variam o E_{CONT} ao longo do dia. Neste trabalho, utilizou-se E_{CONT} constante para todos os períodos, ou seja, de acordo com um contrato *flat*;
- V_{CONT} , em R\$/kWh, é o valor pago pela quantidade de energia vendida. É utilizado nas Eq. 3.1 e Eq. 3.2, de modo que L_{MR} e L_{MCP} sejam calculados;
- C_{BESS} , em R\$, é o custo de aquisição do BESS;

Já os parâmetros variáveis de entrada, apresentados na Tabela 14, apresentam valores diferentes a cada passo t do período otimizado. Os valores com o subscrito $_{pas}$ representam valores do passado. Já os valores com o subscrito $_{fut}$ representam as previsões ou projeções realizadas para o futuro. Após a Tabela 14 eles são descritos com mais detalhe.

Tabela 14 – Parâmetros variáveis de entrada.

Posição temporal	Descrição	Símbolo	Limite inferior	Limite superior	Unidade
Passado	Potência PV do passado	$P_{PV,pas}$	0	10	kW
	Temperatura BESS do passado	$T_{BESS,pas}$	-	-	°C
	Potência BESS do passado	$P_{BESS,pas}$	- 5	5	kW
Futuro	Previsão da potência PV	$P_{PV,fut}$	0	10	kW
	Previsão da temperatura BESS	$T_{BESS,fut}$	-	-	°C
	Preço de venda da energia	PLD	-	-	R\$/kWh

Fonte: Autor.

Ao longo deste trabalho, quando algum parâmetro é descrito sem o subscrito temporal $_{pas}$ ou $_{fut}$, significa que a descrição é aplicada tanto para o passado quanto para o futuro. Esses parâmetros temporais foram inseridos na modelagem de forma a descrever as diferenças entre alguns parâmetros que são medidos nos equipamentos (passado) ou previstos (futuro).

Os dados do passado são lidos nos equipamentos a partir do sistema de comunicação da usina, conforme descrito na Seção 2.2.3. Como a função objetivo maximiza o lucro a cada dia, os dados do passado correspondem ao dados medidos do dia atual, a partir de 0 h, até a hora da otimização que está sendo realizada.

- $P_{PV,pas}$, em kW, é a potência medida no inversor vinda dos módulos PV;

- $P_{BESS,pas}$, em kW, é a potência medida no inversor que chega do BESS (descarregamento) ou que está sendo enviada ao BESS (carregamento);
- $T_{BESS,pas}$, em °C, é a média das temperaturas das células das baterias, medidas no BESS;
- $P_{PV,fut}$, em kW, é a previsão da potência PV que será gerada pelos módulos PV, descrita na Seção 3.2.3;
- $T_{BESS,fut}$, em °C, é a previsão da temperatura do BESS;
- PLD , em R\$, é o Preço Líquido das Diferenças, já descrito na Seção 3.2.2. Varia conforme a oferta de energia do SIN. Nos meses de estiagem, por exemplo, há pouca geração hidrelétrica e portanto as termelétricas precisam ser acionadas, fazendo com que o preço de venda de energia aumente. Pode ser coletado diretamente no site da CCEE (CCEE, 2022).

Observa-se na lista acima que os parâmetros P_{PV} e T_{BESS} são entradas variáveis da otimização, seja referente ao passado (medições dos equipamentos) ou ao futuro (previsões). Já P_{BESS} é um parâmetro variável de entrada somente quando referente ao passado. Quando referente ao futuro, P_{BESS} não é um parâmetro variável de entrada pois ele é uma das variáveis de decisão apresentadas na Tabela 12.

3.2.4.4 Restrições

Há restrições que estabelecem os limites mínimos e máximos de cada VD. Essas podem ser incluídas na modelagem como equações no seguinte formato:

$$\text{Limite}_{\text{inf}} \leq \text{Parâmetro} \leq \text{Limite}_{\text{sup}} \quad (3.9)$$

No entanto, *frameworks* de MXs como o *Pyomo* permitem que esses limites sejam inseridos na definição dos parâmetros em si, sem haver necessidade de criar equações adicionais para estabelecê-los. Os parâmetros e seus limites mínimos e máximos foram apresentados na Tabela 12.


De forma adicional às restrições que estabelecem os limites de cada VD e parâmetro de entrada, existem restrições que estabelecem relações entre as VDs e os parâmetros de entrada. Estas últimas são apresentadas a seguir.

3.2.4.4.1 Balanço de Potência

O balanço de potência é a relação entre $P_{G,t}$, $P_{PV,t}$ e $P_{BESS,t}$, calculado com a Eq. 3.10. Valores positivos de $P_{BESS,t}$ significam que o BESS está descarregando, e valores negativos, carregando.

$$P_{GRID,t} = P_{BESS,t} + P_{PV,t} \quad (3.10)$$

Figura 17 – Balanço de potência realizado ao redor do inversor.



Fonte: Autor.


As variáveis P_G , P_{PV} e P_{BESS} são medidas no inversor. Portanto, o volume de controle do balanço de potência é o inversor, conforme a Fig. 17 mostra. Já as potências medidas nos demais equipamentos e locais - BESS, módulos PV e rede elétrica - são um pouco maiores ou menores do que as potências medidas no inversor, devido às eficiências de cada equipamento. Portanto:

- A potência que sai dos módulos PV em direção ao inversor é igual a $\frac{P_{PV}}{\eta_{inversão}}$;
- A potência que sai do inversor em direção à rede elétrica é igual a $\frac{P_G}{\eta_{GRID}}$;
- A potência que sai do BESS em direção ao inversor é igual a $\frac{P_{BESS}}{\eta_{descarga}}$;
- A potência vinda do inversor, convertida para energia química armazenada no BESS, é igual a $P_{BESS} \cdot \eta_{carga}$.

3.2.4.4.2 Cálculo do SOC

O *SOC* do BESS, em kWh, é calculado com a Eq. 3.11, que é estabelecida a partir do balanço de energia ao redor do BESS, apresentado na Fig. 18,

Figura 18 – Balanço de energia realizado ao redor do BESS.



Fonte: Autor.

$$SOC_t = SOC_{t-1} - P_{BESS,c} \cdot p \cdot \eta_{carga} - \frac{P_{BESS,D} \cdot p}{\eta_{descarga}} \quad (3.11)$$

onde p é a proporção do período da amostra em relação a 60 min. Por exemplo, para $t = 10$ min, $p = \frac{1}{6}$.

3.2.4.4.3 Custos de degradação devido ao uso

C_{DOD} é o custo associado à profundidade de descarga da bateria, na Eq. 3.8. Esse custo é maior quanto mais o BESS é degradado durante o uso. C_{DOD} é muito menor que L_{TOTAL} . Logo, a otimização acontecerá no sentido de calcular todas as possíveis operações que resultem no mesmo L_{TOTAL} , e selecionar a operação que menos degrade o BESS. C_{DOD} é calculado com a Eq. 3.12,

$$C_{DOD} = C_{BESS} \cdot \frac{E_t}{E_T} \quad (3.12)$$

onde C_{BESS} é o custo de compra do BESS (Tabela 13) em R\$, E_t é a energia, em kWh, usada durante o ciclo atual e E_T é a energia total, em kWh, utilizável durante a vida útil do BESS. E_T é calculado com a Eq. 3.13 (OLIVEIRA et al., 2022),

$$E_T = N \cdot DOD_{avg} \cdot Q \quad (3.13)$$

onde N é a quantidade estimada de meses de vida útil do BESS e DOD_{AVG} é a profundidade de descarga média do período T . N é calculado com a Eq. 3.14, adaptada de Swierczynski et al. (2015).

$$N = \left(\frac{EOL}{0,00024 \cdot e^{0,02717 \cdot (273,15 + T_{BESS})} \cdot 0,02982 \cdot DoD^{0,4904}} \right)^2 \quad (3.14)$$

A Eq. 3.14 apresenta T_{BESS} no expoente, tornando o problema de otimização exata em um problema exponencial, limitando a quantidade de *solvers* que conseguem resolver o problema.

Ainda referente à Eq. 3.12, E_t é a quantidade de energia utilizada durante cada passo t . E_t é calculado com a Eq. 3.15.

$$E_t = DoD(t) \cdot Q \quad (3.15)$$

3.2.4.4.4 Custos de degradação devido ao não uso

C_{CA} , na Eq. 3.8, é o custo, em R\$, associado ao período no qual o BESS não foi utilizado, visto que a bateria é degradada quando não é utilizada por muito tempo. C_{CA} é calculado com a Eq. 3.16,

$$C_{CA} = \frac{C_{BESS}}{Lft \cdot 30} \quad (3.16)$$

onde Lft , calculado com a Eq. 3.17, é o tempo de vida do BESS, em meses. O número 30 é a quantidade de dias por mês, podendo ser substituído por 28 ou 31, de acordo com a quantidade de dias no mês.

$$Lft = \frac{EOF}{(0.019 \cdot SOC^{0.823} + 0.5195) \cdot (3.258 \cdot 10^{-9} \cdot T_{BESS}^{5.087} + 0.295)}^{1.25} \quad (3.17)$$

Os parâmetros na Eq. 3.17, EOF , SOC e T_{BESS} , foram previamente apresentados na Tabela 13.

3.2.4.4.5 Custo de suavização de P_G

C_{SUAV} , na Eq. 3.8, é o custo, em R\$, de suavização da potência fornecida à rede elétrica P_G . Esta função de custo foi criada com o objetivo de minimizar as variações abruptas de P_G , de forma a fornecer uma energia de melhor qualidade à rede elétrica. C_{SUAV} é calculado com a Eq. 3.18,

$$C_{SUAV} = \sum_t^T (P_{G,t} - P_{G,t-1})^2 \quad (3.18)$$

que calcula o quadrado da diferença entre $P_{G,t}$ e $P_{G,t-1}$.

3.3 Resultados e Discussão

Nesta seção são apresentados os resultados. Primeiramente, na Seção 3.3.2 é apresentada a comparação do L_{TOTAL} e tempo de execução do MH e do MX. Após, na Seção 3.3.3 compara-se o resultado de L_{total} com P_{BESS} amostrado em $p = 60$ min e $p = 10$ min, de modo a estudar o impacto da amostragem na otimização. Na Seção 3.3.4, é apresentado o impacto do custo C_{SUAV} na curva de P_G . Após na Seção 3.3.5 é apresentado o impacto da incerteza da previsão de $P_{PV,fut}$ em L_{TOTAL} . E por último, é apresentado o ganho em L_{TOTAL} obtido com o acoplamento e otimização de um BESS em uma usina PV.

Optou-se por apresentar os resultados para um dia específico, de modo a mostrar como é o resultado de cada dia. No entanto, apresenta-se também a média dos resultados para um período de dias, de modo a mostrar a média destes resultados. Foram escolhidos dois dias para exemplificar o tipo de resultado gerado a cada dia. Esses dias são:

- 18 de novembro de 2023: o PLD deste variou de R\$/kW 0,06 a R\$/kW 1,70. Este dia foi selecionado para apresentar os seguintes resultados:
 - a comparação do L_{TOTAL} otimizado pelo MX e pelo MH em função do tempo de execução, na Seção 3.3.2.
 - o impacto da incerteza da previsão de $P_{PV,fut}$ na variação da projeção de $P_{BESS,fut}$ e L_{TOTAL} ao longo do dia, na Seção 3.3.5;
- 23 de novembro de 2023: O PLD deste dia se manteve constante no valor de R\$/kWh 0,06904. Ou seja, não houve variação do PLD , e portanto a projeção de $P_{BESS,fut}$ não realiza *time shifting* neste dia. Foi selecionado este dia para apresentar os seguintes resultados:
 - a influência da amostragem no resultado de L_{TOTAL} , na Seção 3.3.3;
 - o impacto da função custo C_{SUAV} na curva de P_G , na Seção 3.3.4.


Antes de apresentar os resultados mencionados acima, é apresentada a relação entre os parâmetros otimizados L_{MR} , L_{MCP} e L_{TOTAL} na próxima seção.

3.3.1 Relação entre L_{MR} , L_{MCP} e L_{TOTAL} .

Conforme apresentado na Eq. 3.4, L_{TOTAL} é igual a soma de L_{MR} e L_{MCP} . Na Fig. 19 são apresentados os valores de L_{MR} , L_{MCP} e L_{TOTAL} ao longo dos 363 dias analisados. Observa-se que em 9,92% dos dias, L_{MCP} é negativo (abaixo da linha preta tracejada). Nestes dias, foi gerada uma quantidade de energia menor do que E_{CONT} , e logo, o gerador

de energia sofreu prejuízo perante o MCP. No entanto, o lucro total L_{TOTAL} é sempre positivo, visto que o lucro fixo L_{MR} é sempre maior que o lucro variável L_{MCP} . Na média dos 363 dias, L_{MCP} representou 10,27% de L_{TOTAL} .

Figura 19 – Relação entre L_{MR} , L_{MCP} e L_{TOTAL} para os 363 dias analisados.



Fonte: Autor.

Os valores L_{TOTAL} , L_{MR} e L_{MCP} são dependentes dos parâmetros de entrada descritos nas Tabelas 13 e 14. Destes, dois parâmetros importantes são V_{CONT} e E_{CONT} , utilizados nas Eq. 3.1 e Eq. 3.2. Logo, o fato de L_{MCP} as vezes ser negativo depende do valor escolhido para o parâmetro de entrada E_{CONT} , e da energia gerada pela usina. L_{MCP} é negativo nos dias muito nublados, onde há pouca irradiância.

O parâmetro L_{MR} é sempre fixo, e portanto ele não é modificado pela otimização. A otimização consegue modificar somente L_{MCP} , que conforme já citado, corresponde a em torno de 10% do L_{TOTAL} .

Os resultados apresentados neste trabalho são sempre em relação à L_{TOTAL} , visto que é o parâmetro mais importante ao gerador de energia. No entanto, é interessante, ao considerar o desempenho do lucro otimizado nos resultados deste trabalho, que uma melhoria de 1% em L_{TOTAL} foi originada a partir de uma melhoria de 10% no L_{MCP} .

3.3.2 Comparação entre o resultado da otimização utilizando MH e MX


Um problema de otimização pode ser resolvido de diferentes maneiras. Conforme citado na Seção 3.1.1, diferentes MXs e MHs já foram utilizados para otimizar o despacho de um BESS. De forma a comparar a otimização realizada por MXs e MHs, neste trabalho os dois métodos foram executados e seus resultados são comparados.

O método GA foi utilizado para representar os MHs. Utilizar outro MH resultaria em um resultado diferente do resultado produzido pelo GA. Na verdade, os MHs apresentam resultados diferentes a cada execução, mesmo que seja com o mesmo algoritmo. Isso acontece devido à aleatoriedade dos MHs. Logo, recomenda-se que a análise dos resultados do MH seja feita a partir da média de várias execuções, de forma a diluir o efeito da aleatoriedade.

A comparação entre o MX e MH foi realizada com uma versão simplificada da modelagem, descrita na Seção 3.2. Foram retirados da função objetivo (Eq. 3.8) os custos C_{DOD} , C_{CA} , C_{SUAV} , e deixado somente o parâmetro L_{TOTAL} . Conforme vai se acrescentando restrições ao problema e o mesmo vai se tornando mais complexo, a resolução do mesmo se torna mais difícil e o desempenho do MH tende a piorar comparado ao do MX.

Visto que o resultado do GA é diferente a cada execução, o mesmo foi executado 100 vezes para cada dia, e a seguir é apresentada a média dessas 100 execuções para o dia 18 de novembro de 2023.

Figura 20 – Valor do L_{TOTAL} otimizado por um MH em função do tempo de execução, em comparação com o L_{TOTAL} otimizado por um MX, para o dia 18 de novembro de 2023.



Fonte: Autor.

Observa-se na Fig. 20 que o MH resolve o modelo com maior rapidez do que o MX. A primeira execução do MH acontece aos 0,561 s, enquanto o MX demora 2,871 s. Isso acontece por que o MH executa o modelo com valores aleatórios para a variável de decisão P_{BESS} . Já o MX demora mais para acabar a sua execução, visto que ele não só executa as restrições do algoritmo, mas constrói todo o espaço de busca do problema de forma a encontrar o melhor resultado. O MX encontra o melhor resultado (melhor global) aos 2,871 s, $L_{TOTAL} = \text{R\$ } 7,053$, identificado como um ponto vermelho na Fig. 20. Conforme o tempo de execução passa na Fig. 20, o resultado do MH tende a se aproximar ao resultado do MX. No entanto, mesmo após as 100 execuções que demoraram 18,080 s, ele ainda não

chegou ao resultado calculado pelo MX. Os resultados da otimização feita pelo MX e MH em função do tempo de execução são apresentados na Tabela 15.

Tabela 15 – Valor otimizado pelo MX em comparação com os valores otimizados pelo MH em diferentes iterações.

Tempo	Resultado do MX	Resultado do MH	Iteração do MH
00,561 s	-	R\$ 6,88	1
01,129 s	-	R\$ 6,90	4
02,871 s	R\$ 7,05	-	-
03,150 s	-	R\$ 6,95	14
18,080 s	-	R\$ 6,96	100


Fonte: Autor.

O MX é executado apenas uma vez e apresenta apenas um resultado, R\$ 7,053, aos 2,871 s. O resultado calculado pelo MH no momento mais próximo ao tempo de execução do MX (3,150 s) é igual a R\$ 6,951, que é um resultado 1,45% menor que o do MX.

Na centésima iteração do MH, que aconteceu aos 18,080 s, o MH teve como resultado R\$ 6,96, que é um valor 1,28% menor que o do MX.

Esta mesma comparação, que foi apresentada acima para o dia 18 de novembro de 2023, foi realizada para 363 dias entre agosto de 2022 e janeiro de 2024. Foi calculada a diferença entre o L_{TOTAL} calculado pelo MX e pelo MH, e a distribuição desta diferença é apresentada na Fig. 21.

Figura 21 – Distribuição da diferença entre o L_{TOTAL} calculado por um MH e por um MX.



Fonte: Autor.


Em 17 dias dos 363 analisados (ou em 4,68% dos dias analisados) o MH encontrou resultados considerados iguais aos do MX, visto que a diferença de L_{TOTAL} entre os dois foi menor do que R\$ 0,001. A diferença máxima ocorreu para o dia 02 de novembro de 2023, igual a 5,45%, e a diferença média para os 363 dias foi de 1,99 %.

Visto que L_{TOTAL} calculado pelo MX é sempre maior ou igual que o calculado pelo MH, e visto que o tempo de execução do MX é próximo ao tempo de execução das primeiras iterações do MH, se justifica a escolha realizada de usar o MX para resolver o problema proposto.

3.3.3 Impacto da amostragem no resultado da otimização

O PLD de cada dia é divulgado às 23h00 do dia anterior, de forma que a projeção de $P_{BESS,fut}$ e L_{TOTAL} possa ser realizada. A previsão de $P_{PV,fut}$ realizada no começo do dia, assim como o PLD , possui amostragem horária, ou seja, $p = 60$ min. Logo, é intuitivo que a projeção de $P_{BESS,fut}$ tenha $p = 60$ min também. É apresentada na Fig. 22 a projeção de $P_{BESS,fut}$ otimizada com $p = 60$ min para o dia 23 de novembro de 2023. Para as otimizações apresentadas nas Fig. 22 e Fig. 23, foi retirada a função custo C_{SUAV} da Eq. 3.8.

Figura 22 – Projeção de $P_{BESS,fut}$ feita com $p = 60$ min.




Fonte: Autor.

As 00h00 deste dia, a carga do BESS era a carga mínima, $SOC_0 = 2$ kWh, e portanto o BESS não atua até quando exista P_{PV} disponível. Visto que não há variação do PLD ao longo do dia, não há vantagem em armazenar parte de P_{PV} de modo que essa energia seja vendida mais tarde (*times shifting*), visto que parte dessa energia seria dissipada devido às eficiências $\eta_{inversão}$, η_{carga} , $\eta_{descarga}$ e η_{GRID} , e consequentemente o lucro seria reduzido. No entanto, caso não houvesse BESS, a energia gerada a partir de potências acima de P_{lim} seria desperdiçada. Logo, a energia em excesso, armazenada entre as 08h30 e 14h00, e descarregada das 15h00 as 23h00 na Fig. 22, seria desperdiçada.

De forma a comparar o impacto de p da variável $P_{BESS,fut}$ no resultado de L_{TOTAL} , é apresentada na Fig. 23 a projeção de $P_{BESS,fut}$ feita com $p = 10$ min. É válido ressaltar

que a amostragem dos dados de entrada PLD e $P_{PV,fut}$ continua sendo $p = 60$ min.

Figura 23 – Projeção de $P_{BESS,fut}$ feita com $p = 10$ min.



Fonte: Autor.

A função objetivo (Eq. 3.8) quando otimizada, seja utilizando $t = 60$ min ou $t = 10$ min, retorna o mesmo resultado $L_{TOTAL} = \text{R\$ } 7,94$. Ou seja, o resultado de L_{TOTAL} é independente da amostragem escolhida para a projeção de P_{BESS} , e independente da amostragem dos parâmetros de entrada PLD e $P_{PV,fut}$.


Visto que a amostragem das entradas não altera o resultado de L_{TOTAL} , optou-se por utilizar a amostragem $t = 10$ min, de modo que a potência P_{BESS} fornecida como *set point* ao EMS possua mais variações, e seja mais próxima às variações do GHI real, de forma semelhante às amostragens apresentadas na Fig. 8.

3.3.4 Impacto do custo C_{SUAV} na curva de P_G

A potência projetada $P_{BESS,fut}$ é a potência que servirá de *set point* para a potência de operação do BESS ao longo do dia.

O custo C_{SUAV} é inserido na Eq. 3.8 para suavizar P_G , de modo que cause menos instabilidade na rede elétrica. Este custo não tem influência em L_{TOTAL} , porém tem influência na curva de P_G . Ou seja, ele modifica a curva de P_G sem alterar L_{TOTAL} .

De modo a mostrar o impacto de C_{SUAV} na curva de P_G , as figuras acima Fig. 22 e Fig. 23, mostram os resultados da Eq. 3.8 sem conter C_{SUAV} . Já a figura abaixo, Fig. 24, apresenta o resultado da Eq. 3.8 completa, com o custo C_{SUAV} incluído.

Figura 24 – Projeção de $P_{BESS,fut}$ suavizada, a partir da inserção de C_{SUAV} na otimização.

Fonte: Autor.

Como se vê na Fig. 24, a variação de P_G é menos abrupta do que a variação de P_G apresentada nas Fig. 22 e Fig. 23, fornecendo desta maneira uma energia de melhor qualidade à rede elétrica.

3.3.5 Impacto da incerteza da previsão de $P_{PV,fut}$ na projeção de $P_{BESS,fut}$ e L_{TOTAL} ao longo de um dia.

A acurácia da previsão de $P_{PV,fut}$ é inversamente proporcional à proximidade do período que vai ser previsto. Logo, convém realizar previsões ao longo do dia, quando se está mais próximo ao período que vai ser previsto. Portanto, a projeção de P_{BESS} também varia ao longo do dia.


De forma a mostrar a variação das projeções de $P_{BESS,fut}$ devido às variações de $P_{PV,fut}$ ao longo de um dia, são apresentadas nas Fig. 25, Fig. 26, Fig. 27 e Fig. 28 as projeções feitas para quatro horários diferentes do dia 18 de novembro de 2023. Conforme apresentado na Tabela 15, neste dia o L_{TOTAL} projetado às 00h00 é igual a R\$ 7,053. No entanto, no resultado da Tabela 15, não havia sido considerada a incerteza da previsão de $P_{PV,fut}$. Logo, a projeção de L_{TOTAL} ao longo do dia pode ser maior ou menor do que R\$ 7,053, dependendo do erro da previsão de $P_{PV,fut}$.

Nas figuras abaixo há uma linha vertical que marca o momento no qual a projeção foi realizada. Esse momento é o mesmo no qual L_{TOTAL} foi projetado, apresentado na caixa superior à esquerda de cada figura.

A primeira projeção, apresentada na Fig. 25, é feita no primeiro horário do dia, 00h00m. Neste momento, a amostragem de $P_{PV,fut}$ é igual a $p = 60$ min para todos os

t passos. A projeção deste momento é de $L_{TOTAL} = \text{R\$ } 7,19$, que é 1,94% maior que o L_{TOTAL} caso a previsão não cometesse erros.


Figura 25 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 00h00 do mesmo dia.



Fonte: Autor.

É apresentado na Fig. 26 uma outra projeção de L_{TOTAL} , feita às 05h00. Nesse momento, já há previsões de $P_{PV,fut}$ com amostragem $p = 10$ min. A previsão feita às 05h00 contém a amostragem $p = 10$ min para a próxima hora (das 05h00 as 06h00), e $p = 60$ min para as demais horas (06h00 as 23h00). A previsão da próxima hora apresenta uma probabilidade menor de erro em relação às próximas horas. Observa-se que a projeção de L_{TOTAL} apresentou o valor $\text{R\$}/\text{kWh } 6,74$, que é 4,39% menor que o L_{TOTAL} caso a previsão não cometesse erros.

Figura 26 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 05h00 do mesmo dia.




Fonte: Autor.

Já a projeção apresentada na Fig. 27 é feita às 08h40. De maneira análoga à Fig. 26, a previsão de $P_{PV,fut}$ da Fig. 27 das 08h40 até as 09h40 possui $p = 10$ min, e $P_{PV,fut}$ do restante do dia possui $p = 60$ min.

Os dados à esquerda da linha vertical cinza são dados do passado, lidos nos equipamentos. Os dados do passado ainda fazem parte da projeção, visto que o período de otimização é fixo das 00h00 às 23h50 de cada dia. No entanto, os dados do passado não são mais variáveis de decisão, e sim são parâmetros fixos de entrada. A projeção de L_{TOTAL} deste horário, igual a R\$ 7,01, é 0,5 % menor que o L_{TOTAL} caso a previsão não cometesse erros.


Figura 27 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 08h40 do mesmo dia.



Fonte: Autor.

A projeção apresentada na Fig. 28 é feita às 16h40. A previsão de $P_{PV,fut}$ dos próximos intervalos do dia (16h50, 17h00, ... , 23h50) não é mais alterada, devido à irradiância ser muito baixa a partir desse momento. Portanto, as projeções de $P_{BESS,fut}$ e do L_{TOTAL} também não são mais alteradas. Logo, neste dia, às 16h40 já se sabe que o lucro do dia será $L_{TOTAL} = \text{R\$}/\text{kWh } 7,04$, que é 0,14 % menor que o lucro sem erros de previsão.

Figura 28 – Projeção do L_{TOTAL} para o dia 18 de novembro de 2023, realizada às 16h40 do mesmo dia.




Fonte: Autor.

Nas Fig 25, Fig. 26, Fig. 27 e Fig. 28 viu-se o impacto da incerteza da previsão ao longo do dia 18 de novembro de 2023 como exemplo. Na Fig. 29 vê-se a variação do L_{TOTAL} calculado com o erro da previsão, em comparação com o L_{TOTAL} sem o erro da previsão, para este mesmo dia.

Conforme pode ser visto na Fig. 29, ao longo da manhã, até umas 10h00, a variação é grande e ao longo do restante do dia vai diminuindo. Conforme se chega no meio da tarde, em torno das 14h00, a irradiância já é baixa e portanto o erro da previsão de GHI tem pouca influência sobre L_{TOTAL} . Às 16h40 já se tem certeza do L_{TOTAL} do dia (R\$ 7,04), e vê-se que ele é um pouco menor do L_{TOTAL} caso não houvesse erro de previsão (R\$ 7,05).

Figura 29 – Impacto da incerteza da previsão de GHI na projeção de L_{TOTAL} ao longo do dia 18 de novembro de 2023.




Fonte: Autor.

Conforme visto, o L_{TOTAL} varia para mais e menos ao longo do dia, e no final do dia acaba sendo um pouco menor do que o L_{TOTAL} caso a previsão fosse ideal (sem erros).

A Fig. 30 apresenta a média da diferença entre o L_{TOTAL} calculado com e sem erro de previsão para 363 dias diferentes. Na Fig. 30 foi considerado o erro absoluto, portanto é sempre positivo.

Figura 30 – Distância entre o resultado considerando previsão sem erro e o resultado considerando previsão realística.



Fonte: Autor.


Conforme se vê na Fig. 30, a diferença no começo do dia apresenta valores próximos a 2%, e ao final do dia, em torno de 0,2%.

Portanto, o impacto das incertezas da previsão de $\sigma = 0,2$ para $p = 60$ min e de $\sigma = 0,05$ para $p = 10$ min, descritas na Seção 3.2.3, é de apenas 0,2% no L_{TOTAL} da usina. Isto indica que o método utilizado de previsões feitas em janelas deslizantes ao longo do dia faz com que o lucro não sofra grande queda, apesar da grande incerteza da previsão. Isto acontece pois, conforme o andamento do dia, novas previsões de P_{PV} e novas projeções de P_{BESS} são realizadas, fazendo com que esse erro varie bastante ao longo do dia, mas seja diminuído de 2% (começo do dia) para 0,2% ao final do dia, conforme ilustrado na Fig. 29.

3.3.6 Comparação entre L_{TOTAL} com BESS otimizado e sem BESS

De forma a ilustrar o aumento de L_{TOTAL} causado pelo acoplamento de um BESS a uma usina PV, mostra-se na Fig. 31 o L_{TOTAL} da usina PV/BESS otimizada neste trabalho comparado com o L_{TOTAL} para a mesma usina PV sem BESS acoplado.


Figura 31 – Comparação entre L_{TOTAL} otimizado da usina PV/BESS e o L_{TOTAL} de uma usina PV sem BESS.



Fonte: Autor.

Conforme visto na Fig. 31, L_{TOTAL} da usina PV/BESS otimizada é sempre maior que o L_{TOTAL} da usina PV. Isso ocorre pois, em primeiro lugar, o BESS permite que a energia produzida nos momentos que $P_{PV} > P_{lim}$ seja armazenada e não mais descartada. E em segundo lugar, a otimização do BESS escolhe o melhor horário para o despacho da energia armazenada, vendendo a energia ao melhor preço e portanto maximizando L_{TOTAL} .

Figura 32 – Comparação entre L_{TOTAL} calculado por uma usina PV com BESS otimizado e uma usina PV sem BESS.



Fonte: Autor.

A Fig. 32 apresenta a distribuição do ganho percentual de L_{TOTAL} da usina PV/BESS em relação à usina PV para os 363 dias analisados. O L_{TOTAL} médio da usina PV/BESS (R\$ 7,20) é 6,94% maior que o L_{TOTAL} médio (R\$ 6,78) da usina PV sem BESS.

Observa-se na Fig. 32 que os ganhos da usina PV/BESS ficam, em sua maioria, até 10% a mais que os ganhos de uma usina PV. O ganho máximo ocorreu para o dia 28/09/2023, no qual o L_{TOTAL} da usina PV/BESS foi igual a mais que o triplo (212,78% maior) do L_{TOTAL} da usina PV. Isso aconteceu devido à grande variação do PLD nesse dia.

Esta grande variação no L_{TOTAL} da usina PV que ocorreu no dia 28/09/2023, assim como em outros dias, aconteceu devido à usina PV ser vulnerável à variação do PLD . Neste dia o PLD apresentou um valor muito alto em um momento no qual não havia irradiância, fazendo com que a usina PV sofresse prejuízo perante o MCP. Já a usina PV/BESS, além de não sofrer prejuízo nesse momento, consegue obter um bom lucro, visto que ela descarrega energia neste momento, vendendo a energia a um preço alto.

3.4 Conclusão

Neste trabalho, o despacho da energia de uma usina PV/BESS foi otimizado com o objetivo de maximizar L_{TOTAL} . O uso do BESS otimizado pelo algoritmo desenvolvido permite que a variação do PLD se torne uma ferramenta de obtenção de lucro, em vez de um fator de insegurança aos *stakeholders*. Por exemplo, em 28/09/2023, a usina PV/BESS obteve mais de três vezes o lucro de uma usina PV sem BESS.

No entanto, durante o período no qual os dados foram coletados (2022 e 2023), houve pouca variação do PLD . Este período foi o de menor variação desde a série histórica disponível a partir de 2018, conforme apresentado na Fig. 12. Logo, a maior parte do lucro obtido neste período de PLD quase sempre constante, foi obtida a partir do *peak shaving* realizado quando $P_{PV} > P_{lim}$.

O ganho médio de lucro obtido com a instalação do BESS para o período analisado foi de 6,94%. Se o PLD voltar a variar como em anos anteriores, o lucro da usina PV com a instalação do BESS será ainda maior.

Dois métodos de otimização foram analisados neste estudo: um MX (programação não linear com equações quadráticas e exponenciais) que chegou ao resultado de 6,94% descrito no parágrafo anterior, e um MH (Algoritmo Genético). O MH tem dificuldades de encontrar soluções boas para o problema completo com os custos C_{DOD} , C_{CA} e C_{SUAV} , e portanto, na comparação desses dois métodos, estes custos foram removidos. Ou seja, a comparação foi realizada com uma versão simplificada do problema onde a Função Objetivo (Eq. 3.8) é igual ao L_{TOTAL} . Com essa versão simplificada, o MH chegou a resultados, na média, 1,99% menores que os do MX. Conforme o algoritmo vai se tornando mais complexo, essa diferença tende a aumentar. Logo, o uso do MX para resolver o problema proposto foi justificado.

A otimização realizada considerou não apenas a maximização do lucro, mas também a maximização da vida útil das baterias, a partir do uso de custos que favorecem o uso em momentos menos quentes (C_{DOD}) e que evitam longos períodos de inatividade das baterias (C_{CA}), visto que estes dois fatores diminuem a vida útil das baterias.

Além disso, a qualidade da energia fornecida à rede elétrica foi considerada, a partir do uso do custo C_{SUAV} que força a usina PV/BESS a fornecer potência à rede elétrica sem variações abruptas, que causam instabilidades na rede elétrica.

Trabalhos relacionados ao despacho de baterias em usinas PV/BESS geralmente consideram a previsão de P_{PV} como se fosse perfeita. Ou seja, é considerado que o gerenciador de energia já sabe qual a energia que será gerada pelos módulos PV com antecedência. Visando contribuir com esse assunto, neste trabalho o erro da previsão foi simulado e o seu impacto foi estimado. Um método de previsão em duas etapas, realizadas em janelas deslizantes ao longo do dia, foi implementado, fazendo com que o impacto do erro da previsão simulada caísse de 2% no começo do dia para 0,2%.

A proposta deste trabalho foi a de resolver o despacho de um BESS de modo exato, com equações complexas encontradas na literatura que comumente são resolvidas apenas por MHs. O resultado encontrado é um dado financeiro (L_{TOTAL}), no entanto o foco deste trabalho não foi o de analisar a viabilidade financeira de se instalar BESSs em usinas PV. Este foco pode ser dado a trabalhos futuros.

Outra sugestão de trabalhos futuros é trabalhar com a otimização na etapa do planejamento da construção da usina PV/BESSs, otimizando parâmetros que foram considerados constantes neste trabalho. Nestes parâmetros, estão inclusos a potência nominal do sistema PVs; a capacidade de armazenamento das baterias Q ; e os limites máximo e mínimo da potência P_{BESS} . Esse dimensionamento pode ser útil em análise financeiras que incluem o cálculo do tempo de retorno financeiro. Outros parâmetros fixos que podem ser tornar variáveis em trabalhos futuros são o valor do contrato V_{CONT} e a energia contratada E_{CONT} , de modo que o contrato de venda de energia da usina seja otimizado.

A potência otimizada do BESS resultante da otimização serve de *set point* de operação deste equipamento. Com o intuito de aprimorar a qualidade da energia, foi incorporada à otimização uma função de custo para suavizar a curva da potência fornecida à rede elétrica. Essa abordagem busca reduzir as flutuações bruscas dessa potência, minimizando assim a sobrecarga nos equipamentos de transmissão e distribuição. Portanto, a metodologia desenvolvida não só otimiza o desempenho econômico da usina PV/BESS, mas também contribui significativamente para a estabilidade e desempenho do sistema elétrico com como um todo.

Referências

AL-MAAITAH, S. S.; AL-MAJALI, H. D. Particle swarm optimizer for bess operation to mitigate voltage deviation of the modified ieee 9-bus power system. In: . [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2021. p. 31–36. ISBN 9781665442930. Citado na página 54.

BARBOUR, E.; GONZÁLEZ, M. C. Projecting battery adoption in the prosumer era. *Applied Energy*, v. 215, p. 356–370, 2018. ISSN 03062619. Citado na página 55.

BLOOMBERG. *Global Energy Storage Market to Grow 15-Fold by 2030* / BloombergNEF. 2022. Acessado em 02-07-2023. Disponível em: <<<https://about.bnef.com/blog/global-energy-storage-market-to-grow-15-fold-by-2030/>>>. Citado 2 vezes nas páginas 21 e 53.

CALLOQUISPE-HUALLPA, R. et al. A comparison between genetic algorithm and particle swarm optimization for economic dispatch in a microgrid. In: . [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2023. p. 415–419. ISBN 9798350336962. Citado na página 53.

CCEE. *Painel de Preços - CCEE*. 2022. Acessado em 17-03-2024. Disponível em: <<<https://www.ccee.org.br/web/guest/precos/painel-precos>>>. Citado 3 vezes nas páginas 56, 61 e 72.

CCEE2. *Procedimentos de Comercialização*. <<https://www.ccee.org.br/mercado/procedimentos-de-comercializacao>>. Acessado em 20-06-2024. Citado na página 61.

COINOR. *Interior Point Optimizer - IPOPT*. 2024. Acessado em 17-03-2024. Disponível em: <<<https://github.com/coin-or/Ipopt>>>. Citado na página 59.

EBERHART, R.; KENNEDY, J. New optimizer using particle swarm theory. *Proceedings of the International Symposium on Micro Machine and Human Science*, p. 39–43, 1995. Citado na página 53.

GAMS. *GAMS - Cutting Edge Modeling*. 2023. Acessado em 10-11-2023. Disponível em: <<<https://www.gams.com/>>>. Citado na página 54.

HANNAN, M. A. et al. Battery energy-storage system: A review of technologies, optimization objectives, constraints, approaches, and outstanding issues. *Journal of*

- Energy Storage*, Elsevier Ltd, v. 42, p. 103023, 2021. ISSN 2352152X. Disponível em: <<<https://doi.org/10.1016/j.est.2021.103023>>>. Citado 3 vezes nas páginas 20, 21 e 53.
- HOLLAND, J. H. Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence. *Adaptation in Natural and Artificial Systems*, The MIT Press, 1 1992. Disponível em: <<<https://direct.mit.edu/books/book/2574/Adaptation-in-Natural-and-Artificial-SystemsAn>>>. Citado na página 53.
- INMET. *Instituto Nacional de Meteorologia - INMET*. 2024. Acessado em 17-03-2024. Disponível em: <<<https://portal.inmet.gov.br/>>>. Citado na página 63.
- JEDDI, B.; MISHRA, Y.; LEDWICH, G. Dynamic programming based home energy management unit incorporating pvs and batteries. *IEEE Power and Energy Society General Meeting*, v. 2018-Janua, p. 1–5, 2018. ISSN 19449933. Citado na página 53.
- KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering and System Safety*, v. 91, p. 992–1007, 9 2006. ISSN 09518320. Citado na página 58.
- LOPES, A. D. C. et al. Avaliação de desempenho de tecnologias emergentes para controle de tensão em redes de distribuição com elevada penetração de microgeração fotovoltaica. 2020. Citado na página 54.
- MOHAMED, A. A. R. et al. A Comprehensive Robust Techno-Economic Analysis and Sizing Tool for the Small-Scale PV and BESS. *IEEE Transactions on Energy Conversion*, IEEE, v. 37, n. 1, p. 560–572, mar 2022. ISSN 0885-8969. Disponível em: <<<https://ieeexplore.ieee.org/document/9521731/>>>. Citado na página 69.
- MONTOYA, O. D.; GIL-GONZÁLEZ, W.; GRISALES-NOREÑA, L. F. An exact minlp model for optimal location and sizing of dgs in distribution networks: A general algebraic modeling system approach. *Ain Shams Engineering Journal*, Faculty of Engineering, Ain Shams University, v. 11, p. 409–418, 2020. ISSN 20904479. Disponível em: <<<https://doi.org/10.1016/j.asej.2019.08.011>>>. Citado na página 55.
- OLIVEIRA, L. M. et al. Gerenciamento Ótimo de energia elétrica para maximização de lucro de uma planta fotovoltaica com baterias. In: . [S.l.]: SBA Sociedade Brasileira de Automática, 2022. Citado na página 74.
- OPENDSS. *Open Distribution System Simulator*. 2023. Acessado em 17-03-2024. Disponível em: <<<https://www.epri.com/pages/sa/opensdss>>>. Citado 2 vezes nas páginas 54 e 55.
- OSORIO, D. M. A review in bess optimization for power systems. p. 1–32, 2023. Citado 3 vezes nas páginas 10, 53 e 54.

PYOMO. *Pyomo - Python Optimization Modeling*. 2023. Acessado em 12-05-2023. Disponível em: <<<http://www.pyomo.org/>>>. Citado na página 54.

RAINVILLE, F. M. D. et al. Deap: A python framework for evolutionary algorithms. *GECCO'12 - Proceedings of the 14th International Conference on Genetic and Evolutionary Computation Companion*, Association for Computing Machinery, p. 85–92, 2012. Citado na página 58.

ROSS, R. G. Design techniques for flat-plate photovoltaic arrays. In: *Proceedings of the 15th IEEE Photovoltaic Specialists Conference*. [S.l.: s.n.], 1986. Citado na página 64.

SOROUDI, A. *Power system optimization modeling in GAMS*. [S.l.]: Springer International Publishing, 2017. 1-295 p. ISBN 9783319623504. Citado na página 55.

SOROUDI, A. *DEDESSwind : Cost based Dynamic Economic Dispatch integrated with Energy Storage and Wind*. 2023. Acessado em 17-03-2024. Disponível em: <<https://www.gams.com/latest/psoptlib_ml/libhtml/psoptlib_DEDESSwind.html>>. Citado na página 55.

SOTO, W. D.; KLEIN, S. A.; BECKMAN, W. A. Improvement and validation of a model for photovoltaic array performance. *Solar Energy*, Elsevier Ltd, v. 80, p. 78–88, 2006. ISSN 0038092X. Citado na página 64.

SWIERCZYNSKI, M. et al. Lifetime estimation of the nanophosphate lifepo4/c battery chemistry used in fully electric vehicles. *IEEE Transactions on Industry Applications*, Institute of Electrical and Electronics Engineers Inc., v. 51, p. 3453–3461, 7 2015. ISSN 00939994. Citado na página 74.

ZIA, M. F.; ELBOUCHIKHI, E.; BENBOUZID, M. Optimal operational planning of scalable DC microgrid with demand response, islanding, and battery degradation cost considerations. *Applied Energy*, Elsevier, v. 237, n. October 2018, p. 695–707, mar 2019. ISSN 03062619. Disponível em: <<<https://doi.org/10.1016/j.apenergy.2019.01.040https://linkinghub.elsevier.com/retrieve/pii/S0306261919300406>>>. Citado na página 55.

Capítulo 4

Previsão de irradiância baseada em fotos do céu para suavizar a potência fotogerada

Resumo

Neste trabalho é descrito o desenvolvimento de um método de previsão de curtíssimo prazo para variações de GHI causadas por sombreamento de nuvens, visando a suavização da potência fornecida à rede elétrica por usinas PV. O método proposto utiliza uma rede neural híbrida CNN-LSTM. As camadas CNNs extraem características das fotos da ASC, enquanto as LSTMs processam os dados de séries temporais GHI , DHI e variação da irradiância de céu claro. O modelo apresentou um erro médio absoluto de 46,751 W/m². A aplicabilidade da previsão foi testada através de um algoritmo de suavização de P_G , permitindo a antecipação e mitigação das variações de potência. O principal parâmetro do algoritmo suavizador é o limite de variação de P_G , que foi estabelecido como sendo igual a 1,007 kW/min, equivalente a 10% da potência nominal da usina experimental utilizada no estudo. Em um período analisado, a previsão da variação de GHI permitiu ao algoritmo suavizador eliminar as 15 ultrapassagens desse limite a partir do uso do BESS, evidenciando o potencial do método proposto para melhorar a qualidade da energia fornecida à rede elétrica por usinas PV. Os resultados são promissores, no entanto é necessário aprofundar o desenvolvimento do algoritmo suavizador e testá-lo em diferentes cenários, de modo a obter uma conclusão mais detalhada.

Palavras-chaves: Previsão, CNN-LSTM, Suavização, fotovoltaica, câmera de céu.

Abstract

This work describes the development of a very short-term forecasting method for *GHI* variations caused by cloud shading, aiming to smooth the power supplied to the electrical grid by PV plants. The proposed method uses a hybrid CNN-LSTM neural network. The CNNs layers extract features from ASC photos, while the LSTMs processes time series data of *GHI*, *DHI*, and clear sky irradiance variation. The model presented a mean absolute error of 46.751 W/m². The applicability of the forecast was tested through a P_G smoothing algorithm, allowing the anticipation and mitigation of power variations. The main parameter of the smoothing algorithm is the P_G variation limit, which was set at 1.007 kW/min, equivalent to 10% of the nominal power of the experimental plant used in the study. In an analyzed period, the *GHI* variation forecast allowed the smoothing algorithm to eliminate 15 exceedances of this limit through the use of a BESS, demonstrating the potential of the proposed method to improve the quality of energy supplied to the electrical grid by PV plants. The results are promising, however, it is necessary to further develop the smoothing algorithm and test it in different scenarios to obtain a more detailed conclusion.

Keywords: Forecast, CNN-LSTM, Smoothing, photovoltaic, sky camera.

4.1 Introdução

Nos últimos anos, os modelos de *Deep Learning* têm recebido bastante atenção por apresentarem bom desempenho em relação aos modelos convencionais (matemáticos e estatísticos) de previsão, devido à três razões: eles extraem automaticamente características dos dados, sem a necessidade de conhecimento prévio; possuem capacidade de generalização; possuem habilidade para lidar com grandes conjuntos de dados (KAWAGUCHI; KAEHLING; BENGIO, 2017).

Os modelos de *Deep Learning* possuem bom desempenho em diferentes aplicações, como processamento de imagem, extração de padrões, classificação e a previsão (KHODAYAR; WANG, 2019), como é o exemplo da previsão de *GHI* realizada neste trabalho.

As previsões de *GHI* servem a aplicações diferentes de acordo com o seu horizonte *hrz* e amostragem *p* de previsão. A classificação da Tabela 16, criada a partir da classificação descrita em Kumari e Toshniwal (2021), é uma sugestão de separação entre tipos de previsões de *GHI*.

Tabela 16 – Classificação da previsão de energia solar baseada na amostragem e horizonte.

Nome	Horizonte	Amostragem	Tipo de aplicação
Curtíssimo Prazo	até 1 h	até 10 min	Monitoramento e controle
Curto/Médio Prazo	de 1 h a 1 dia	de 10 min a 1 h	Balanceamento e despacho de energia, Mercado de curto prazo
Longo Prazo	mais de 1 semana	mais de 1 h	Alocação, Planejamento de manutenção, Estudos financeiros

Fonte: Autor.

Na Seção 3.2.3, por exemplo, foram descritas duas previsões de *GHI* que serviram de entrada ao algoritmo de otimização do despacho do BESS. De acordo com a Tabela 16, a previsão de maior prazo dessa otimização, de $p = 1$ h e $hrz \leq 24$ h, pode ser classificada como previsão de médio prazo. Já a previsão de menor prazo, de $p = 10$ min e $hrz = 1$ h, pode ser classificada como de curto prazo.

Já a previsão de curtíssimo prazo descrita na Tabela 16 é aquela que tem amostragens pequenas que vão de poucos segundos até poucos minutos. Normalmente, este tipo de previsão é associado ao controle e monitoramento de usinas (KUMARI; TOSHNIWAL, 2021).

A previsão de curtíssimo prazo de geração P_{PV} , também chamada de *nowcast*, possui uma dificuldade maior em relação às de maiores amostragens, devido à natureza estocástica da atmosfera e das nuvens (FABEL et al., 2024). A passagem de uma nuvem pode causar uma redução abrupta no *GHI*, seguida por um aumento igualmente rápido

quando a nuvem se move. Para capturar essas variações com precisão, é fundamental utilizar técnicas de amostragem em intervalos curtos.

Nesse sentido, as imagens de ASC como as coletadas com o SC descrito na Seção 2.2.3, podem fornecer informações importantes como a quantidade de minutos que faltam para a nuvem interceptar o Sol e causar a queda de GHI , e consequentemente P_{PV} .

A utilização de ASCs para monitorar a cobertura e o movimento das nuvens tem se mostrado uma abordagem promissora para melhorar a precisão das previsões *nowcast* de GHI . Imagens capturadas por essas câmeras permitem a análise detalhada das nuvens em tempo real, possibilitando a identificação rápida de mudanças que impactam o GHI .

Dos métodos que capturam fotos de ASCs e as inserem como entrada em algoritmos de previsão incluem os que utilizam considerações físicas - a partir do tratamento das imagens estimam a espessura e cinética da nuvem, métodos de dados que incluem algoritmos estatísticos, e os métodos que utilizam técnicas de *deep learning*, que são o foco deste trabalho. Estes últimos utilizam redes neurais profundas para aprender automaticamente características relevantes das imagens e padrões temporais complexos, sem necessidade de modelagem explícita dos fenômenos físicos.

A seção a seguir descreve trabalhos encontrados na literatura relacionados à previsão de GHI a partir do uso de imagens de câmeras que tiram fotos do céu.

4.1.1 Revisão da Literatura

Kumari e Toshniwal (2021) realizaram uma revisão abrangente de métodos de previsão de GHI que utilizam técnicas de *Deep Learning*, incluindo modelos como LSTM (*Long Short Term Memory*), DBN (*Deep Belief Network*), CNN (*Convolutional Neural Network*), ESN (*Echo State Network*), RNN (*Recurrent Neural Network*) e GRU (*Gated Recurrent Unit*). Os autores destacam que para previsões de curtíssimo prazo, o uso de imagens de ASCs ou de satélite melhora o desempenho da previsão. Das técnicas de utilizam imagens, citam o uso de modelos híbridos como o CNN-LSTM (utilizado por Guariso, Nunnari e Sangiorgio (2020) e Yeom et al. (2020)) e GRU-LSTM, que demonstraram melhorias significativas no desempenho da previsão em diferentes horizontes de tempo.

Paletta, Arbod e Lasenby (2023) usaram, como entrada do seu algoritmo de previsão de GHI , imagens de satélite de $p = 5$ min, imagens de ASCs de $p = 1$ a 2 min e GHI s. O pré-processamento das imagens incluiu redimensionar as fotos da ASC de 768×1024 para 128×128 pixels e "desembrulhar" as imagens, oriundas de uma lente tipo olho de peixe, em imagens retangulares, de modo a reduzir a distorção da imagem hemisférica. Foram testados horizontes de previsão de curto prazo de $hrz = 10$ min a $hrz = 60$ min. Compararam os resultados dos modelos que utilizam apenas uma das fontes de imagens

(satélite ou ASC), e o da combinação dessas duas entradas. O modelo com somente imagens da ASC obteve melhor desempenho para $hrz = 10$ min (RMSE = 112,6 W/m²), enquanto que para $hrz > 25$ min, os modelos ASC + satélite obtiveram melhor desempenho (RMSE = 125,8 W/m²).

Sarkis et al. (2024) utilizaram um modelo híbrido CNN-LSTM para prever GHI a partir de fotos do céu. O modelo foi treinado usando fotos capturadas por duas *webcams* que giram e capturam fotos 360° do horizonte, e não câmeras especializadas como as ASCs, com o objetivo de estudar a viabilidade de se usar câmeras de vigilância públicas de usinas PV para auxiliarem a previsão. Foram testadas diferentes abordagens, como usar as fotos das duas câmeras lado a lado em uma imagem só, usar as duas fotos como imagens separadas, ou usar só uma das duas fotos. Também foram testadas diferentes técnicas de aprendizado de máquina como ARIMA, CNN e CNN-LSTM. Foram utilizados dados de três meses de $p = 10$ min. A abordagem com as fotos separadas das duas câmeras que utilizou a técnica CNN-LSTM obteve o melhor desempenho (RMSE = 42,39 W/m²), resultado este que é próximo ao de soluções comerciais. É válido ressaltar que este erro foi encontrado para previsão de médio prazo de $hrz = 120$ min.

Nijhum, Kenny e Dev (2024) utilizaram no seu algoritmo de previsão de curtíssimo prazo o modelo pré-treinado de visão computacional **MobileNetV2** disponível em Keras Team (2023) e um *dataset* de fotos infravermelhas de céu e irradiância solar disponível em Girasol (2021). Chegaram a um resultado considerado muito bom para previsões de curtíssimo prazo de RMSE = 16,18 W/m². No entanto, não mencionam ao longo do trabalho qual foram a amostragem e horizonte utilizados.

O artigo de Logothetis et al. (2022) teve como objetivo avaliar o desempenho de quatro modelos de previsão de GHI baseados em fotos de ASC, incluindo modelos que utilizam métodos físicos e métodos de aprendizado de máquina. Classificaram os dados de GHI em eventos de rampa (momentos de início e fim do sombreamento) e não-rampa. Os modelos foram avaliados quanto à sua capacidade de prever corretamente esses eventos para $hrzs \leq 20$ min. Utilizaram $p = 1$ min para todos os modelos. Os resultados mostram que os sistemas baseados em aprendizado profundo detectaram entre 49% e 92% dos eventos de rampa verdadeiros, enquanto os físicos, entre 26% e 51%. No entanto, os modelos físicos apresentaram menor taxa de falsos positivos (<10%) em comparação com os sistemas de aprendizado profundo (até 85%). Os autores concluíram que a escolha do método mais adequado depende da aplicação específica e que uma combinação de abordagens físicas e de aprendizado profundo poderia melhorar ainda mais as previsões de eventos de rampa.

Ogliari, Sakwa e Cusa (2024) fizeram a previsão de GHI a partir de fotos de ASC utilizando uma câmera infravermelha e $p = 1$ min. As imagens foram pré-processadas e redimensionadas para 128x128 pixels. O modelo utiliza como entrada, além das fotos, dados de GHI do passado e a irradiância de céu limpo, que é uma estimativa do GHI

caso não ocorra sombreamento ao longo do dia. Foram testados os horizontes $hrz = 5, 10$ e 15 min, com janelas deslizantes de $2, 4$ e 8 min, respectivamente. A rede neural utilizada, chamada de *Enhanced Convolutional Neural Network* (ECNN), insere dados como o GHI junto à matriz de pixels da imagem. Compararam o método desenvolvido com o método persistente, que considera que o próximo GHI é igual ao anterior. Os resultados mostraram que o modelo desenvolvido superou o método de persistência em $5,04\%$, $9,57\%$ e $9,07\%$ para horizontes de $5, 10$ e 15 min, respectivamente. Em condições de alta flutuação de irradiância, o modelo superou o persistente em 19% para todos os horizontes testados.

Na literatura recente destacam-se algumas soluções de suavização de potência em usinas PV frente aos efeitos de sombreamento, descritas nos próximos parágrafos. Essas soluções utilizam somente previsão de sombreamento, somente armazenamento de energia, ou utilizam uma combinação dos dois.

Zhang et al. (2021) trabalharam com previsão e com armazenamento. Propuseram-se a reduzir a quantidade de baterias de forma a reduzir os custos da solução. Como inovação, estabeleceram quatro limites para o SOC e criaram regras para a bateria quando dentro de cada limite, de forma a aumentar a vida útil do BESS. Estabeleceram esses limites a partir de uma análise de sensibilidade.

Ryu, Ishii e Hayashi (2021) utilizaram previsão e armazenamento para auxiliar uma usina PV/BESS a não ultrapassar o limite de 1% de $\Delta P_G/min$ em relação à potência nominal da usina, que fica em uma região isolada no Japão. A previsão de quanta energia será gerada caso o céu esteja limpo utiliza técnicas de *Deep Learning* feita com dados históricos de geração. Em relação à esta primeira previsão, a câmera de céu prevê o quanto P_{PV} cairá devido ao sombreamento. A solução foi modelada e simulada com dados reais de geração de um sistema PV. Compararam com a solução que chamam de convencional, que utiliza armazenamento e não utiliza previsões. A solução proposta reduziu a potência necessário de armazenamento em 10% .

Em outro trabalho dos mesmos autores do trabalho supracitado (ANDO et al., 2021), é descrito com mais detalhes como a previsão é feita. Utiliza-se uma rede neural convolucional (CNN) que recebe como entrada as imagens da câmera de céu e a irradiância global direta medida nos instantes anteriores à previsão. A função de custo utilizada mede o erro quadrático médio entre o GHI previsto e o medido. Os dados de entrada são amostrados em $p = 1$ min, e a previsão pode ser feita para $hrz = 1$ a 20 min. As imagens foram reduzidas de 2048×1536 para 100×100 pixels de modo a não estender o tempo de treinamento das redes neurais.

Dissawa et al. (2021) não utilizam armazenamento. Se propuseram a desenvolver um método de previsão de queda da P_{PV} no qual utilizaram duas ASCs. Com a triangulação entre a nuvem e as duas ASCs conseguem estimar a altura da nuvem, que junto com a modelagem cinemática, permite que a previsão de sombreamento seja feita não somente

para o local onde as imagens foram obtidas, mas para até 2 km de distância do local das câmeras, o que reduz os custos com câmeras para uma usina PV de grande extensão. Fizeram previsões de GHI de $hrz = 1$ e 5 min, onde obtiveram precisão de 80% e 78%.

Na literatura, métodos diferentes de suavização de P_{PV} são descritos, que utilizam ASC e/ou BESS. Neste trabalho, é descrito um método de suavização que utiliza BESS e ASC. O BESS é utilizado de modo que a energia cortada para a realização da suavização não seja desperdiçada, e a ASC, para que a suavização seja realizada de forma antecipada.

4.1.2 Objetivo Geral

Desenvolver um método de previsão de curtíssimo prazo, baseado em fotos de uma ASC, da variação de GHI causada por sombreamento de nuvens, visando a suavização de P_G .

4.1.3 Objetivos Específicos

- Desenvolver um modelo híbrido de CNN-LSTM para realizar a previsão de GHI a partir dados solares calculados, medidos, e fotos da ASC, de modo a antecipar as variações de GHI causadas por sombreamento;
- Avaliar o desempenho do modelo de previsão de GHI desenvolvido através de análises quantitativas e qualitativas, de modo a validar se ele possui uma acurácia mínima que permita a sua utilização na redução da variação de P_G .
- Integrar a previsão de GHI em um algoritmo de suavização de P_G , de modo a analisar como a previsão pode auxiliar o algoritmo a realizar a suavização.

4.2 Metodologia

Nesta seção é descrita a metodologia empregada no desenvolvimento do modelo de previsão de GHI de curtíssimo prazo que utiliza fotos da ASC, e do algoritmo de suavização de P_G .

Primeiramente, na Seção 4.2.1 são apresentados os parâmetros de entrada do modelo, incluindo dados solares medidos e calculados, bem como as fotos da ASC. Em seguida, na Seção 4.2.2, a estrutura e a funcionalidade das camadas das redes CNN e LSTM são descritas. Após, na Seção 4.2.3 são descritas as métricas utilizadas para avaliar o desempenho do modelo de previsão. E por último, na Seção 4.2.4 é descrito o desenvolvimento do algoritmo de suavização de P_G .

4.2.1 Parâmetros de entrada do modelo


O modelo desenvolvido possui como entrada parâmetros solares medidos, parâmetros solares calculados, e fotos da ASC.

4.2.1.1 Parâmetros medidos

As irradiâncias *GHI* e *DHI* são dados da estação meteorológica Ammonit, coletados pelo SC descrito na Seção 2.2.3. O *GHI* é o principal parâmetro de entrada do modelo, visto que ele é o parâmetro que será previsto. A partir dele, a potência gerada pelos módulos PVs pode ser estimada. Já o *DHI* não é um parâmetro previsto, mas pode ser inserido como entrada no modelo de modo que auxilie a previsão de *GHI*.

É apresentado na Fig. 33 a variação dos parâmetros *GHI* e *DHI* ao longo de um dia.

Figura 33 – Parâmetros medidos utilizados como entrada do modelo de previsão, ao longo do dia 18 de dezembro de 2022.



Fonte: Autor.

Conforme pode ser observado na Fig. 33, durante o dia utilizado como exemplo, 18 de dezembro de 2022, o *GHI* variou consideravelmente antes do meio-dia solar (11:15 deste dia) devido ao sombreamento causado por nuvens. Os momentos de sombreamento fazem com que o *DHI* cresça e o *GHI* diminua. Já nos momentos após o meio-dia solar na Fig. 33, a variação de *GHI* ocorreu de maneira mais suave, com influência menor de nuvens.

Outra observação que pode ser feita em relação à nebulosidade observada durante a manhã do dia analisado na Fig. 33 é que o tempo de sombreamento foi sempre curto, causado por nuvens pequenas. Esse tipo de sombreamento é causado por nuvens baixas

e/ou rápidas, características de cidades de região litorânea. Como excessão, observa-se que entre 06h00 e 07h00 houve um sombreamento de maior duração.

Outro parâmetro solar comumente utilizado, além dos GHI e DHI , é o DNI . No entanto, optou-se por não utilizar o DNI como entrada do modelo, principalmente, porque a estação meteorológica utilizada não mede diretamente o DNI , e sim faz considerações e calcula este parâmetro indiretamente.

4.2.1.2 Parâmetros calculados

De forma a auxiliar a previsão de GHI são calculados parâmetros adicionais, descritos a seguir.


4.2.1.2.1 Irradiância de Céu Claro

Um parâmetro muito utilizado na previsão de GHI é a Irradiância de Céu Claro (GHI_{CLEAR}), conforme a usada no trabalho de Ogliari, Sakwa e Cusa (2024). O GHI_{CLEAR} é uma estimativa da irradiância que alcançaria a superfície da Terra se não houvesse nuvens ou outros elementos atmosféricos que pudessem absorver, espalhar ou refletir a luz solar. Em outras palavras, é o GHI que seria observado na superfície terrestre sob condições ideais de transparência atmosférica.

Antonanzas-Torres et al. (2019) citam vários modelos para calcular GHI_{CLEAR} . Destes, foi utilizado o modelo de Perez-Ineichen (PEREZ et al., 2002) devido a sua fácil implementação a partir do uso do *framework* `PVLib` em Python. Os parâmetros de entrada utilizados são apenas a latitude e longitude, além do período no qual que ser obter o GHI_{CLEAR} . A latitude e longitude do local da usina experimental PV/BESS com ASC é igual a $-7,1195^\circ$ e $34,845^\circ$, respectivamente.

Logo, o GHI_{CLEAR} tem a forma e valores próximos ao GHI real, conforme apresentado na Fig. 34.

Figura 34 – Comparação entre GHI medido e o GHI_{CLEAR} estimado para o dia 18 de dezembro de 2022.




Fonte: Autor.

O parâmetro que vai ser previsto é o GHI . Pretende-se que o GHI_{CLEAR} auxilie a rede neural não com o valor da irradiância que deve ser prevista, mas sim auxilie a saber se a irradiância a ser prevista deve ser maior ou menor, de acordo com o horário do dia, visto que o GHI_{CLEAR} aumenta até o meio-dia solar, e diminui após. Para tanto, talvez uma entrada que ajude mais nesse sentido seja a variação de GHI_{CLEAR} em relação ao tempo (ΔGHI_{CLEAR}).

4.2.1.2.2 Variação da Irradiância do Céu Claro

A variação de ΔGHI_{CLEAR} ao longo de um dia é apresentada na Fig. 35.

Figura 35 – Variação de ΔGHI_{CLEAR} ao longo do dia dia 18 de dezembro de 2022.



Fonte: Autor.

O objetivo principal de ΔGHI_{CLEAR} é indicar se a tendência do GHI é crescer ou diminuir, de acordo com o horário do dia, visto que:

- $\Delta GHI_{CLEAR} = 0$ antes do Sol nascer e após se por, e também ao meio-dia solar, quando a irradiância para de crescer e começa a diminuir;
- $\Delta GHI_{CLEAR} > 0$ entre o nascer do Sol e o meio-dia solar, visto que GHI_{CLEAR} cresce neste momento.
- $\Delta GHI_{CLEAR} < 0$ entre o meio-dia solar e o pôr do Sol, visto que GHI_{CLEAR} decresce neste momento.


Os parâmetros solares medidos (GHI e DHI) e calculados (ΔGHI_{CLEAR}) foram utilizados como parâmetros de entrada do modelo. Estes dados são importantes à previsão, principalmente quando o céu está limpo. Já quando ocorre um sombreamento, essa informação não está presente nestes dados. Para tanto, são utilizadas as fotos da ASC, que contém imagens de nuvens ou céu claro próximas ao Sol.

4.2.1.3 Fotos da câmera de céu

A descrição da coleta, pré-processamento e sincronização do *timestamp* das fotos da ASC com os dados de séries temporais foi descrita na Seção 2.2.4.

As fotos resultantes do pré-processamento são matrizes de 64 x 64 pixels em escala de cinza. Cada pixel é representado por um valor numérico entre 0 e 255, onde 0 corresponde ao preto puro e 255 ao branco puro. Os valores intermediários representam diferentes tons de cinza. A Fig. 36 mostra alguns exemplos de fotos da ASC.

Figura 36 – Exemplos de fotos da ASC.



Fonte: Autor.

Diferentes elementos das fotos da ASC (nuvens, céu claro, Sol coberto, Sol descoberto) da Fig. 36 são representados por faixas distintas de valores de pixel:


- Céu claro: é escuro nas fotos preto e brancas da ASC, e geralmente apresenta valores de pixel baixos, tipicamente até 50.
- Sol descoberto: quando visível, o Sol é representado por um grupo arredondado de pixels com valores muito altos, geralmente acima de 230. Este agrupamento circular é uma característica distintiva do Sol não obstruído.
- Sol coberto por nuvens: quando parcialmente obstruído por nuvens, os pixels correspondentes ao Sol ainda apresentam valores altos, mas o padrão circular característico se torna mais difuso e irregular. Os valores variam de acordo com a densidade da nuvem que cobre o Sol.
- Nuvens: as nuvens aparecem em tons de cinza mais claros que o céu ao fundo, mas geralmente mais escuros que o Sol. Os valores de pixel para nuvens variam amplamente, tipicamente entre 50 e 200, dependendo de sua densidade e proximidade

ao Sol. Nuvens longe do Sol tendem a apresentar valores mais baixos, enquanto nuvens próximas ao Sol tendem a ter valores mais altos.

Esta distribuição de valores de pixel permite que a rede neural identifique e diferencie os elementos-chave da imagem, como a presença e posição do Sol, a cobertura de nuvens e áreas de céu claro. Essas informações são cruciais para a previsão precisa de variações no *GHI* devido ao sombreamento por nuvens.

Na Fig. 37, é aplicado um zoom sistemático em uma imagem, até chegar aos elementos unitários da foto, os pixels, de modo a exemplificar os diferentes valores de pixel para as diferentes cores.

Figura 37 – Sequência de zooms aplicados a uma foto da ASC



Fonte: Autor.

4.2.2 Redes neurais

Os dados de parâmetros solares e fotos da ASC, descritos nas seções anteriores, servem como entrada para o modelo de previsão desenvolvido neste trabalho. Após a revisão da literatura e análise dos diferentes métodos de previsão utilizados para prever o *GHI* em curtíssimo prazo, optou-se por desenvolver uma rede neural híbrida CNN-LSTM. Esta arquitetura foi escolhida devido à sua capacidade de processar eficientemente tanto dados sequenciais quanto informações espaciais das imagens.

Esta seção detalha a estrutura e os componentes das duas redes neurais utilizadas, a LSTM na Seção 4.2.2.1 e a CNN na Seção 4.2.2.2.

4.2.2.1 Rede neural LSTM


As redes LSTMs são uma variante especializada das Redes Neurais Recorrentes (RNNs), projetadas para lidar eficazmente com dependências de longo prazo em séries temporais. Introduzidas por Hochreiter e Schmidhuber (1997), as LSTMs têm a capacidade de aprender, lembrar e esquecer informações seletivamente ao longo do tempo, tornando-as particularmente adequadas para a análise de sequências de dados, como séries temporais de *GHI* (QING; NIU, 2018).

No contexto da previsão de *GHI*, as redes LSTM são capazes de capturar padrões temporais complexos nos dados de irradiância solar (ALZAHIRANI et al., 2017). Elas podem aprender a reconhecer tendências sazonais, ciclos diários e até mesmo padrões meteorológicos de curto prazo que afetam o *GHI*. Por exemplo, uma rede LSTM pode aprender a correlacionar sequências de valores de *GHI* com mudanças nas condições atmosféricas, permitindo previsões mais precisas em diferentes escalas de tempo (WANG et al., 2019).

4.2.2.1.1 Camada LSTM

A rede LSTM é composta por uma série de blocos de memória repetitivos, ou camadas. Cada bloco (Fig. 38) contém três *gates* (portas) principais: *gate* de entrada, *gate* de esquecimento e *gate* de saída. Estes *gates* controlam o fluxo de informação dentro da unidade LSTM (HOUDT; MOSQUERA; NÁPOLES, 2020).

Figura 38 – Ilustração da Camada LSTM da rede neural LSTM.



Fonte: Autor.

São utilizados os seguintes símbolos na Fig. 38:

- $x^{(t)}$ é o vetor de entrada na camada LSTM, composto, no modelo desenvolvido, pelos dados de séries temporais *GHI*, *DHI*, ΔGHI_{CLEAR} .

- $y^{(t)}$ é o vetor de saída da camada atual e $y^{(t-1)}$ da camada anterior, associados à memória de curto prazo que é transmitida através dos blocos. É atualizado com a Eq. 4.1 quando passa pelo *gate* de saída (OG),


$$y^{(t)} = o^{(t)} \odot \tanh(c^{(t)}) \quad (4.1)$$

onde $\odot$ denota a multiplicação elemento a elemento dos vetores e $o^{(t)}$ é a saída do OG, calculada com a Eq. 4.2.

$$o^{(t)} = \sigma(W_{OG} \cdot x^{(t)} + U_{OG} \cdot y^{(t-1)} + V_{OG} \cdot c^{(t)} + b_{OG}) \quad (4.2)$$

Na Eq. 4.2, assim como nas Eq. 4.5, Eq. 4.6 e Eq. 4.7 os parâmetros W , U e V são as matrizes de pesos, que são multiplicadas pelos parâmetros de entrada c^{t-1} , y^{t-1} , e o *bias* b . Observe que o b possui valor fixo para todos as camadas LSTMs. Os subscritos dos pesos e b (IG, FG e OG) indicam a qual *gate* pertencem. Já o símbolo σ , representa a função de ativação sigmoide (Fig. 39 e Eq. 4.3).

Figura 39 – Função σ



$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4.3)$$

Fonte: Autor.

- $c^{(t)}$ é o vetor de saída do bloco atual e $c^{(t-1)}$ do bloco anterior, associados à memória de longo prazo. É atualizado com a Eq. 4.4 quando passa pelos *gates* de entrada (IG) e esquecimento (FG),

$$c^{(t)} = f^{(t)} \odot c^{(t-1)} + i^{(t)} \odot g^{(t)} \quad (4.4)$$

onde $f^{(t)}$ e $i^{(t)}$ são as saídas dos gates FG e IG, calculadas com as Eq. 4.5 e 4.6.

$$f^{(t)} = \sigma(W_{FG} \cdot x^{(t)} + U_{FG} \cdot y^{(t-1)} + V_{FG} \cdot c^{(t-1)} + b_{FG}) \quad (4.5)$$

$$i^{(t)} = \sigma(W_{IG} \cdot x^{(t)} + U_{IG} \cdot y^{(t-1)} + b_{IG}) \quad (4.6)$$


A função σ da Fig. 39 e Eq. 4.3 é utilizada nos *gates* OG, FG e IG (Eq. 4.2, Eq. 4.5 e Eq. 4.6) devido à sua capacidade de produzir valores entre 0 e 1, o que é ideal para valorar a decisão de passar (1) ou não (0) a informação, independente do tamanho do valor de suas entradas.

Ainda na Fig. 38, o bloco com a função tangente hiperbólica ($\tanh$) aparece duas vezes. O $\tanh$ superior da Fig. 38 é utilizado para normalizar o vetor $c^{(t-1)}$ entre -1 e 1. Já o $\tanh$ da parte inferior é utilizado para calcular o parâmetro normalizado $z^{(t)}$, utilizando a Eq. 4.7.

$$z^{(t)} = \tanh(W_Z \cdot x^{(t)} + R_Z \cdot y^{(t-1)} + b_Z) \quad (4.7)$$

A função $\tanh$, ilustrada na Fig. 40, é calculada com a Eq. 4.8. Ela é utilizada porque produz valores entre -1 e 1, permitindo que a rede module a intensidade das informações processadas.

Figura 40 – Função $\tanh$



$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.8)$$

Fonte: Autor.

Ambas as funções σ e ϕ são essenciais para a capacidade da LSTM de aprender, reter e esquecer informações de forma seletiva ao longo do tempo (HOCHREITER; SCHMIDHUBER, 1997; GERS; SCHMIDHUBER; CUMMINS, 2000).

4.2.2.1.2 Camada Densa

A camada densa é um componente fundamental em muitas arquiteturas de redes neurais, incluindo a rede LSTM. Nesta camada, cada neurônio está conectado a todos os neurônios da camada anterior, permitindo que o modelo aprenda padrões complexos e não-lineares nos dados (GOODFELLOW; BENGIO; COURVILLE, 2016).

As camadas densas podem ser utilizadas como camadas de entrada, intermediárias, ou de saída. Quando intermediárias, são conectadas a uma cada densa antes e outra após. Estas são também conhecidas como camadas escondidas. Quando a entrada da camada densa é conectada a um parâmetro de entrada, ela é uma camada densa de entrada. E

quando a sua camada de saída é conectada ao parâmetros de saída da rede neural, é uma camada densa de saída.


Cada neurônio da camada densa calcula uma soma ponderada de todas as suas entradas, seguida por uma função de ativação não-linear (CHOLLET, 2018). Em cada neurônio é utilizada a Eq. 4.9,

$$y = f(W_{DENSE} \cdot x + b_{DENSE}) \quad (4.9)$$

onde y é o vetor de saída, x é o vetor de entrada, W_{DENSE} é a matriz de pesos, b_{DENSE} é o vetor de viés, e f é a função de ativação (ZHANG; WANG; LIU, 2018). Podem ser utilizadas diferentes funções para f , como por exemplo as funções σ e $\tanh$ das Fig. 4.3 e Fig. 4.8.

Na Fig. 41 são exemplificadas quatro camadas densas: uma de entrada, duas intermediárias, e uma de saída. A camada de entrada da Fig. 41 possui três neurônios, cada um associado aos vetores resultantes da saída da camada LSTM, identificadas na figura como GHI^* , DHI^* e ΔGHI_{CLEAR}^* . A camada densa de saída possui apenas 1 neurônio, visto que o algoritmo de previsão possui apenas um parâmetro de saída, o GHI de algum passo no futuro.

Figura 41 – Camadas densas ligadas entre si e aos blocos de entrada e saída.



Fonte: Autor.

Ainda na Fig. 41, foram utilizadas duas camadas intermediárias densas, contendo cada uma quatro neurônios. Observe que a quantidade de camadas e de neurônios por camada intermediária independe do tamanho das camadas densas de entrada e saída. Quanto mais camadas e neurônios há, mais padrões complexos e não-lineares nos dados a rede irá aprender. A camada densa é particularmente eficaz na combinação de características de alto nível extraídas por camadas anteriores, como as camadas LSTM.

Uma característica das camadas densas é que cada neurônio é conectado a todos os outros das camadas antes e depois. Logo, são conhecidos também pelo nome de camadas


totalmente conectadas. Outra característica é a versatilidade das camadas densas. Elas lidam com vetores de entrada independente de sua origem (camadas LSTM, CNN, ou outros) e são utilizadas frequentemente em modelos híbridos (SAGHEER; KOTB, 2019).

A próxima seção descreve as camadas da rede CNN, e como as imagens são processadas por essas camadas.

4.2.2.2 Rede neural CNN

A arquitetura da CNN consiste em várias camadas, incluindo os blocos convolucionais, de *pooling*, camadas densas totalmente conectadas (GOODFELLOW; BENGIO; COURVILLE, 2016), e a camada final de vetorização. A Fig. 42 ilustra um exemplo de arquitetura CNN.

Figura 42 – Camadas da rede CNN.



Fonte: Autor.

A entrada da rede CNN, ilustrada na Fig. 42, é a foto pré-processada da ASC. A foto é um vetor de três dimensões: altura, largura e canais. A altura e largura das fotos tratadas da ASC são iguais a 64 pixels, e visto que as fotos são preto e brancas, possuem 1 canal. Logo, a dimensão da camada de entrada da rede CNN é $m \times m \times c = 64 \times 64 \times 1$.

4.2.2.2.1 Camada de Convolução

Esta é a principal camada da rede CNN. Nela, são aplicados diversos filtros (ou *kernels*) à imagem de entrada. Cada filtro tem dimensões $n \times n$, onde n tem que ser menor que m . Os filtros deslizam sobre a imagem, realizando operações de convolução (LECUN; BENGIO; HINTON, 2015). Normalmente são utilizados dezenas ou centenas de filtros por imagem de tamanhos pequenos como $n \times n = 3 \times 3$, de forma que várias informações diferentes sejam extraídas das imagens.


Logo, a entrada da rede CNN que antes tinha dimensões iguais a $m \times m \times c$, após a camada de convoluções passa a ter a dimensão $(m - n + 1) \times (m - n + 1) \times c$. Ou seja,

cada imagem de dimensão $64 \times 64 \times 1$ gera uma matriz $56 \times 56 \times 32$, caso sejam utilizados 32 filtros de $n = 8$. À medida que os dados fluem através da camada convolucional, a dimensionalidade espacial (altura e largura) diminui, enquanto a profundidade (quantidade de canais) aumenta devido à quantidade de filtros, capturando características cada vez mais abstratas e complexas da imagem original (ZEILER; FERGUS, 2014).

À cada *kernel* são aplicados pesos, semelhantes aos pesos utilizados na rede LSTM. Durante cada época de treinamento, esses pesos são ajustados, permitindo que o *kernel* aprenda a extrair as características significativas.

É apresentado na Fig. 43 um exemplo de operação realizada na camada de convolução. É utilizado um filtro de tamanho 2×2 , aplicado à fatia da foto da ASC da Fig. 37.

Figura 43 – Filtro sendo aplicado à fatia da foto apresentada na Fig. 37.



Fonte: Autor.

As imagens formadas a partir das convoluções desta camada são tipicamente chamadas de mapas de características. Espera-se que estas imagens possuam características destacadas de cada foto, como bordas do Sol e das nuvens. Estes mapas de características são fundamentais para a capacidade da rede em identificar padrões relevantes nas imagens processadas da ASC.

No entanto, a camada de convolução gera uma grande quantidade de dados devido ao número de filtros aplicados, o que pode tornar o processamento da rede lento. O objetivo da próxima camada é lidar com este problema.


4.2.2.2.2 Camada de *Pooling*

O objetivo principal desta camada é reduzir as dimensões espaciais dos mapas de características gerados pela camada de convolução, mantendo ao mesmo tempo as

informações mais importantes. Esta redução não apenas diminui a carga computacional nas camadas subsequentes, mas também ajuda a rede a se tornar mais robusta a pequenas variações nas características da imagem.

Normalmente, utilizam-se dois tipos de operação na camada de *pooling*, chamados de *max pooling* e *average pooling* (SCHERER; M"uLLER; BEHNKE, 2010), exemplificados na Fig. 44. No método *max pooling*, a camada seleciona o valor máximo em uma determinada janela, reduzindo assim o tamanho do mapa de características enquanto preserva as informações mais importantes. Já no *average pooling*, realiza a média dos valores dentro da janela.

Figura 44 – Camada *pooling*




Fonte: Autor.

4.2.2.2.3 Camada de Ativação

Esta camada aplica a função de ativação não-linear ReLU (Fig. 45 e Eq. 4.10) aos mapas de características gerados pela camada convolucional. A função ReLU substitui todos os valores negativos por zero (NAIR; HINTON, 2010). Isso ajuda a introduzir não-linearidade no modelo, permitindo que ele aprenda padrões mais complexos.

Figura 45 – Função ReLU



$$f(x) = \max(0, x) \quad (4.10)$$

Fonte: Autor.

4.2.2.2.4 Camada de Vetorização

Por último, as matrizes de imagens convolucionadas são vetorizadas, de forma a estarem em um formato adequado à utilização em camadas de outras redes, como por exemplo a camada densa e camada LSTM, descritas na Seção 4.2.2.1.

Foram testados diferentes quantidades de camadas da rede LSTM e CNN de modo a formar uma rede híbrida CNN-LSTM. O formato final desta rede é apresentado mais a frente na Seção 4.3.1.

4.2.2.3 Janelas Deslizantes

A saída do algoritmo de previsão é apenas um dado: o GHI^{t+n} onde $t+n$ representa algum passo no futuro. Já a entrada do algoritmo de previsão é composta por quatro dados: GHI , DHI , ΔGHI_{CLEAR} e a foto da ASC.

Convém que não sejam utilizados como entrada dados de apenas um instante t , e sim uma sequência de dados ($t-n$ a t) chamada de janela deslizante. O principal objetivo das janelas deslizantes é permitir que modelos de aprendizado profundo capturem padrões temporais em dados sequenciais (BROWNLEE, 2018). Cada janela compreende um segmento de tempo fixo, que "desliza" ao longo da série temporal, criando sequências de dados temporais. Utilizaram-se janelas deslizantes de dez passos (GHI^{t-9} a GHI^t) para prever o GHI do próximo minuto (GHI^{t+3}), visto que $t = 20$ s para todos os dados utilizados.

Junto à janela deslizante dos dez GHI s, são utilizadas também como entrada janelas deslizantes dos outros parâmetros de entrada: DHI , ΔGHI_{CLEAR} e fotos da ASC.

É válido ressaltar que a janela deslizante de dez imagens da ASC não é criada a partir das imagens de entrada da rede CNN, e sim pelas imagens processadas e vetorizadas de saída da rede CNN. Ou seja, cada uma das dez imagens são processadas individualmente pela rede CNN, como se houvessem dez redes CNN paralelas. Após, os dez vetores de saída de cada rede CNN servem para criar a janela deslizante de imagens da ASC.

4.2.3 Métricas de desempenho

As equações a seguir foram utilizadas para que as métricas de desempenho do modelo possam ser mensuradas.

O erro, calculado com a Eq. 4.11, representa a diferença entre o valor previsto (GHI_{PREV}) e o valor real (GHI_{REAL}).

$$erro = GHI_{PREV} - GHI_{REAL} \quad (4.11)$$

Já o erro absoluto ($|erro|$), calculado com a Eq. 4.12, considera apenas a magnitude da diferença entre GHI_{PREV} e GHI_{REAL} , ignorando a direção da diferença. Isso é útil para avaliar a precisão do modelo sem as compensações que podem ocorrer na média dos erros.

$$|erro| = |GHI_{PREV} - GHI_{REAL}| \quad (4.12)$$

O desvio padrão dos erros, calculado com a Eq. 4.13, mede a dispersão destes em torno da média. Um valor alto indica maior variabilidade dos erros.

$$D_{PADRÃO} = \sqrt{\frac{1}{n} \sum_{i=1}^n (erro_i - \overline{erro})^2} \quad (4.13)$$

As métricas de erro forneçam uma avaliação quantitativa do desempenho do modelo de previsão de GHI . No entanto, julgou-se importante também exemplificar a aplicabilidade da previsão no contexto da operação de uma usina PV/BESS, visto que o objetivo final é utilizar a previsão de queda de GHI para suavizar as variações de P_G . Para tanto, apresenta-se na Seção 4.2.4 a descrição do algoritmo de suavização de P_G desenvolvido.

4.2.4 Algoritmo de Suavização

A previsão foi realizada para o GHI . Visto que o objetivo do algoritmo de suavização é suavizar P_{PV} e não o GHI , o P_{PV} foi simulado a partir do GHI utilizando o mesmo algoritmo de simulação utilizado na Seção 3.2.3, que usa o *framework* PVLib.

Já o algoritmo de suavização foi desenvolvido com o *framework* Pyomo, seguindo a mesma estrutura de algoritmos de otimização descrita na Seção 3.2.4. Foram utilizadas também algumas das variáveis de decisão, parâmetros de entrada e restrições da projeção do BESS já utilizadas, descritas na Seção 3.2.4.

A função objetivo do suavizador (Eq. 4.14) maximiza, para determinadas variáveis de decisão VD, a quantidade de energia $E_{m,t}$ (Eq. 3.3) fornecida à rede elétrica a cada instante t , no entanto mantendo $P_{G,SUAV,t}$ o mais próximo possível do $P_{G,BRUTO,t}$,

$$\max_{VD} F_{OBJETIVO} = \sum_t^T [E_{m,t} - (P_{G,SUAV,t} - P_{G,BRUTO,t})^2] \quad (4.14)$$

onde $P_{G,BRUTO,t}$ é a potência fornecida à rede elétrica sem suavização, e $P_{G,SUAV,t}$ é a potência fornecida à rede elétrica suavizada.

Na otimização do lucro da usina PV/BESS, descrita na Seção 3.2.4, P_G é igual a soma de P_{PV} e P_{BESS} (Eq. 3.10). Já o $P_{G,BRUTO}$ utilizado na Eq. 4.14 é igual somente a P_{PV} , conforme a Eq. 4.15. Dessa forma, é possível estimar o quanto do BESS foi utilizado somente para a suavização, sem a realização de *peak shavings* e *energy arbitrages*.

$$P_{G,REAL,t} = P_{PV,t} \quad (4.15)$$

O somatório do quadrado das diferenças entre $P_{G,SUAV,t}$ e $P_{G,BRUTO,t}$ foi inserido na Eq. 4.14 de modo a fazer com que a energia armazenada não seja descarregada excessivamente. Caso esse somatório não estivesse na Eq. 4.14, a função descarregaria as baterias ao máximo, visto que o objetivo principal é maximizar E_m . Logo, com esta inserção na Eq. 4.14, a bateria é usada somente para evitar que $\Delta P_G/min$ seja ultrapassado.

Ainda Eq. 4.14, os parâmetros t e T são relacionados ao passo que será previsto (GHI^{t+3}) e ao período do limite $\Delta P_G/min$, que são ambos iguais a 1 minuto. Logo, $T = 4$, que é igual a apenas 1m20s, ou quatro passos de $t = 20$ s. O algoritmo de suavização é executado a cada novo passo t .

As VDs utilizadas na suavização são apresentadas na Tabela 17.

Tabela 17 – Variáveis de decisão e seus limites.

Descrição	Símbolo	Limite inferior	Limite superior	Unidade
Varição por minuto de P_G	$\Delta P_G/min,t$	-1,007	1,007	kW/min
Estado de Carga	SOC,t	2	10	kWh
Profundidade de descarga	DOD,t	0	8	kWh
Potência da bateria	$P_{BESS,t}$	-5	5	kW
Potência exportada à rede	$P_{G,SUAV,t}$	0	10	kW
Energia medida	$E_{m,t}$	0	10	kWh

Fonte: Autor.

Algumas das variáveis de decisão da Tabela 17 já foram descritas após serem mencionadas, na Tabela 3.2.4.2. Segue a descrição dos parâmetros ainda não descritos.

- $\Delta P_G/min,t$, em kW/min, é a diferença entre P_G^t e P_G^{t+3} . Os limites inferior e superior foram estabelecidos como sendo iguais a 10% da potência pico da usina PV (10,07 kWp), igual a $\pm 1,007$ kW/min.
- $P_{G,SUAV,t}$, em kW, é a potência suavizada fornecida à rede elétrica. Visto que $T = 4$, são otimizados quatro $P_{G,SUAV,t}$ a cada período otimizado. Para simplificar esta modelagem, o limite do inversor de 5,5 kW foi ignorado, e o limite superior de $P_{G,SUAV,t}$ foi programado para 10 kW.

Os parâmetros fixos de entrada utilizados são apresentados na Tabela 18, e quando ainda não apresentados, são descritos em seguida.

Tabela 18 – Parâmetros fixos de entrada.

Descrição	Símbolo	Valor	Unidade
Capacidade do BESS	Q	10	kWh
Estado de carga inicial	SOC_0	5	kWh
Eficiência do inversor	$\eta_{invers\tilde{o}}$	0,9	-
Eficiência da rede elétrica	η_{GRID}	0,98	-
Eficiência de Carregamento	η_{carga}	0,95	-
Eficiência de Descarregamento	$\eta_{descarga}$	0,95	-

Fonte: Autor.

O valor de SOC_0 , que na modelagem da otimização do lucro da usina PV/BESS era igual ao limite inferior de SOC , que é igual a 2 kWh, foi configurado como sendo igual a 5 kWh. Esta alteração foi feita pois foram feitas simulações iniciando em momentos que não iniciam no começo do dia, e para realizar a suavização, é necessário que exista carga nas baterias.

Os parâmetros variáveis de entrada, na Tabela 19, são todos relacionados ao P_G .

Tabela 19 – Parâmetros variáveis de entrada.

Posição temporal	Símbolo	Limite inferior	Limite superior	Unidade
Passo atual (t)	$P_{G,BRUTO}^t$	0	10	kW
Previsão atual ($t + 3$)	$P_{G,BRUTO}^{t+3}$	0	10	kW
Previsões feitas no passado ($t + 1$ e $t + 2$)	$P_{G,BRUTO}^{t+1},$ $P_{G,BRUTO}^{t+2}$	0	10	kW

Fonte: Autor.

Na Tabela 19:

- $P_{G,BRUTO}^t$ é a potência atual fornecida à rede elétrica.
- $P_{G,BRUTO}^{t+3}$ é a previsão de P_G para o próximo minuto. Esta previsão é realizada no passo atual t .
- $P_{G,BRUTO}^{t+2}$ e $P_{G,BRUTO}^{t+1}$ são as previsões de P_G para o próximo minuto feitas no passo anterior, e no passo antes do anterior.

Como restrição desta modelagem, foram utilizadas as restrições relacionadas ao balanço de potência (Eq. 3.10) e ao cálculo do SOC (Eq. 3.11), descritas na Seção 3.2.4.4.

Na Seção 4.3 são apresentados os resultados da previsão de GHI , e como esta previsão é utilizada para suavizar P_G .

4.3 Resultados e Discussão


Os resultados da previsão de GHI obtidos a partir do modelo híbrido CNN-LSTM, e de como este resultado pode ser utilizado para suavizar P_G estão estruturados em três partes:

- Seção 4.3.1: é descrita a arquitetura final da rede neural híbrida CNN-LSTM.
- Seção 4.3.2: é apresentada a análise quantitativa das métricas de desempenho do modelo, e a análise qualitativa através de gráficos comparativos entre os GHI_{PREV} e GHI_{REAL} .
- Seção 4.3.3: é demonstrado um exemplo da aplicação prática da previsão de GHI na suavização de P_G .

4.3.1 Arquitetura da rede neural híbrida CNN-LSTM.

É apresentada na Fig. 46 a arquitetura final da rede neural híbrida CNN-LSTM.

Figura 46 – Arquitetura da rede neural do modelo de previsão de GHI .



Fonte: Autor.

Na Fig. 46, as fotos da ASC estão identificadas como ASIs (*all-sky images*).

Nos retângulos azuis da Fig. 46 estão os parâmetros de entrada, que são sempre conjuntos de dez dados. As dez ASIs (ASI^{t-9} a ASI^t) são processadas individualmente cada uma por uma rede CNN. Após serem processadas pelas camadas de convolução e *pooling*, as dez ASIs são vetorizadas.

Paralelamente ao processamento das ASIs na rede CNN, as entradas de séries temporais (GHI , DHI e ΔGHI_{CLEAR}) são processadas por uma camada LSTM. Após, os dados de séries temporais são concatenados, na camada Concatenação.

Os dados concatenados passam por uma segunda camada LSTM, seguido de duas camadas Densas. Enfim, a saída da última camada Densa é um parâmetro só, o GHI^{t+3} , em verde na Fig. 46.

Na Seção 4.3.2 é apresentada a análise da comparação entre o GHI_{REAL} e o GHI_{PREV} , que é igual ao parâmetro previsto para o próximo minuto GHI^{t+3} .

4.3.2 Análise Qualitativa e Quantitativa da Previsão

O *dataset* criado para o desenvolvimento do modelo contém 86.524 conjuntos de ASIs e dados de séries temporais GHI , DHI e ΔGHI_{CLEAR} . Todos os dados estão sincronizados e amostrados em 20 s. Apesar da quantidade de fotos, este *dataset* utiliza apenas 396 MB, visto que as fotos já pré-processadas possuem o tamanho de 64x64 pixels, ou 4 kB cada.

A partir destes dados, foi criado outro *dataset* composto por janelas deslizantes de dez passos ($t-9$ a t), resultando em 80.634 janelas deslizantes. Já este *dataset*, que contém muitos dados repetidos, ocupa 4,56 GB de armazenamento.

O *dataset* de janelas foi separado em dados de treinamento, validação e teste. Foram selecionados 25% dos dados para a fase de desenvolvimento do modelo, que inclui o treinamento e a validação do modelo. Foram escolhidos poucos dados para esta fase devido ao tempo de processamento do treinamento do modelo que aumenta com o aumento de dados de entrada.

Logo, sobrou 75% do *dataset* de janelas deslizantes (64.124 janelas deslizantes) para realizar a fase de testes do modelo. Esta quantidade é um pouco excessiva, visto que normalmente são utilizados apenas 10 a 20% dos dados para teste em muitos estudos de aprendizado de máquina, inclusive na área de previsão com ASC (PALETTA; ARBOD; LASENBY, 2023; SARKIS et al., 2024; NIJHUM; KENNY; DEV, 2024).


No entanto, optou-se por analisar a fase de teste em todos os dados inéditos - não vistos nas fases de treinamento e validação, visto que eles estão disponíveis, de modo a obter uma avaliação mais robusta e abrangente do desempenho do modelo. Esta abordagem permite uma análise mais completa do comportamento do modelo em diferentes condições atmosféricas e variações sazonais, fornecendo uma visão mais realista de seu desempenho.

A análise dos resultados da fase de teste foi realizada tanto de forma quantitativa, através das métricas de erro descritas na Seção 4.2.3, quanto de forma qualitativa, por meio de gráficos comparativos entre o GHI_{PREV} e o GHI_{REAL} . Esta combinação de

análises permite uma compreensão mais profunda das capacidades e limitações do modelo desenvolvido.

É apresentado na Fig. 47 o GHI_{PREV} e o GHI_{REAL} para 40.000 amostras da fase de teste.


Figura 47 – Comparação entre GHI_{REAL} e GHI_{PREV} de 40.000 amostras de teste.



Fonte: Autor.

É possível observar na Fig. 47 que o modelo não prevê com acurácia GHI s acima de 1000 W/m^2 . Logo, para GHI_{REAL} s acima de 1000 W/m^2 , o erro tende a ser alto. No entanto, para GHI_{REAL} abaixo de 1000 W/m^2 , o erro tende a ser bem menor, conforme pode ser visto na Fig. 48.

Figura 48 – Comparação entre GHI_{REAL} e GHI_{PREV} de 1.000 amostras de teste.



Fonte: Autor.

A Tabela 20 apresenta algumas métricas de desempenho da previsão de GHI , relacionadas ao erro e $|\text{erro}|$, calculados e descritos na Seção 4.2.3.

Tabela 20 – Métricas de desempenho do modelo de previsão de *GHI* para os erros e os erros absolutos.

Parâmetro	Métrica de Desempenho	Valor (W/m ²)
erro	Média	-0,131
	Desvio padrão	87,701
	Mínimo	-785,348
	Máximo	673,922
erro	Média	46,751
	Quantil 25%	6,820
	Quantil 50%	20,372
	Quantil 99%	414,312
Fonte: Autor.		


A seguir, as métricas de desempenho da Tabela 20 são descritas.

- Média dos erros: A média do erro é a diferença média entre os valores reais e os valores previstos. Visto que o modelo erra tanto para mais quanto para menos, o erro médio não ajuda a concluir sobre a capacidade do modelo. No entanto, o erro médio auxilia a saber se há algum viés de errar para mais, ou para menos. Visto que o erro médio é próximo de 0, dá a entender que não possui viés de sobre ou superestimar. No entanto, mais para frente, a Fig. 50 traz mais informações para concluir sobre esse viés.
- Desvio padrão dos erros: O desvio padrão de 87,701 W/m², é uma medida da dispersão dos erros em torno do erro médio.
- Erro mínimo: O erro mínimo de -785,348 W/m² representa o maior valor de subestimação pelo modelo. Observando a Fig. 47, pode-se ver que essas subestimações ocorrem para valores de *GHI* acima de 1000 W/m².
- Erro máximo: O erro máximo de 673,9219 W/m² é o maior valor de superestimação do modelo, indicando um caso extremo onde o valor previsto foi significativamente maior que o valor real.
- Média dos |erros|: A média dos erros absolutos, 46,751 W/m², é a média das magnitudes dos erros, sem considerar a direção (positiva ou negativa). É uma medida mais intuitiva da precisão do modelo, já que não compensa erros positivos com negativos.
- Quantil de 25% dos |erros|: O primeiro quartil (6,820 W/m²) indica que 25% dos erros absolutos estão abaixo deste valor. Isso representa as previsões mais precisas do modelo.

- Quantil de 50% dos $|\text{erros}|$: A mediana dos erros absolutos, $20,372 \text{ W/m}^2$, é o valor central, onde metade dos erros absolutos estão abaixo e metade estão acima. É uma medida robusta da magnitude típica dos erros, menos afetada por valores incomuns.
- Quantil 99% dos $|\text{erros}|$: O quantil de 99%, igual a $414,312 \text{ W/m}^2$, representa o valor abaixo do qual 99% dos erros absolutos estão localizados. Portanto, ao desconsiderar os 1 % eventos excepcionais de sobreirradiâncias, o $|\text{erro}|$ máximo encontrado é de $414,312 \text{ W/m}^2$.

Ainda sobre os erros da previsão, é apresentado na Fig. 49 um histograma da distribuição dos erros na previsão de GHI . Diferente dos quantis da Tabela 49, o histograma é calculado a partir dos erros, e não dos $|\text{erros}|$. O histograma foi construído utilizando 101 faixas, onde cada faixa contém uma frequência na qual determinado intervalo de erro ocorre.

Figura 49 – Distribuição do Erro da previsão de GHI_{PREV} .



Fonte: Autor.

O histograma da Fig. 49 fornece uma representação visual da distribuição dos erros, permitindo uma análise da distribuição do erro, sua simetria, e concentração dos erros em torno de zero. Para complementar a análise visual da distribuição do erro, são apresentadas na Tabela 21 as frequências e porcentagens das principais faixas de erro da Fig. 49.


Tabela 21 – Principais Faixas do Histograma da Fig. 49.

Início (W/m^2)	Fim (W/m^2)	Contagem	Porcentagem
-62,937	-48,489	1216	3,080
-48,489	-34,040	2046	5,182
-34,040	-19,592	3225	8,168
-19,592	-5,144	5473	13,862
-5,144	9,303	10522	26,651
9,303	23,751	4285	10,853
23,751	38,200	2279	5,772
38,200	52,648	1434	3,632
52,648	67,096	913	2,313

Fonte: Autor.

Observa-se que a faixa central na Tabela 21, que representa 26,651% dos dados, apresentou erro entre -5,144 e 9,303 W/m^2 .

Já na Fig. 50 são apresentados os erros em função do GHI_{REAL} . É possível ver que para GHI s até 700 W/m^2 o modelo tende a superestimar o dado real, visto que há mais erros positivos que negativos. Já para GHI s acima de 700 W/m^2 o modelo tende a subestimar o dado real.

Figura 50 – Erro por GHI_{REAL} .

Fonte: Autor.

Os erros apresentados na análise quantitativa das métricas e qualitativa dos gráficos, nesta seção, indicam o desempenho de previsão do modelo. Já na Seção 4.3.3, é demonstrado um exemplo de como a previsão de GHI pode ser utilizada para reduzir a variação abrupta da potência fornecida por usinas PV/BESS à rede elétrica.


4.3.3 Aplicação da previsão

Selecionou-se o dia 24 de julho de 2023 para exemplificar como a previsão de GHI baseada em fotos de ASC pode auxiliar a usinas PV/BESS a ter a variação de P_G reduzida.

Apresenta-se na Fig. 51 o P_G simulado a partir do GHI_{REAL} ($P_{G,BRUTO}$), e o P_G simulado a partir do GHI_{PREV} ($P_{G,PREV}$). Utilizou-se o subscrito *BRUTO* no lugar de *REAL* em $P_{G,BRUTO}$ pois mais para a frente este vai ser comparado com o P_G suavizado $P_{G,SUAV}$. A simulação dos P_G s a partir dos GHI s foi feita com o algoritmo de simulação descrito na Seção 3.2.3.

Na Fig. 51 são apresentados o $P_{G,BRUTO}$ e o $P_{G,PREV}$, entre as 06h00m e 10h00m do dia 24 de julho de 2023.

Figura 51 – Comparação entre $P_{G,BRUTO}$ e $P_{G,SUAV}$, entre 06h00m e 10h00m do dia 24 de julho de 2023.




Fonte: Autor.

As linhas verticais tracejadas da Fig. 51 delimitam o intervalo entre as 08h07m e 08h30m. Neste intervalo, composto de 69 amostras de $t = 20s$, os limites inferior e superior de $\Delta P_G/min$ (Tabela 18) foram ultrapassados 15 vezes.

A primeira ultrapassagem dos limites de $\Delta P_G/min$ ocorre aos 08m20s, que é a queda abrupta que acontece logo após a primeira linha tracejada vertical da Fig. 51. Neste momento, $P_{G,BRUTO}$ cai abruptamente de 5,746 kW para 2,497 kW. Esta queda é também ilustrada na Fig. 52.

No entanto, na Fig. 52 o $P_{G,PREV}$ não é mais apresentado. É apresentado na Fig. 52 o $P_{G,BRUTO}$, e o resultado da suavização de $P_{G,BRUTO}$ ($P_{G,SUAV}$) feita a partir da modelagem de suavização descrita na Seção 4.2.4.

Figura 52 – Comparação entre $P_{G,BRUTO}$ e $P_{G,SUAV}$, entre 08h07m20s e 08h10m00s do dia 24 de julho de 2023.



Fonte: Autor.


Na Fig. 52, o momento da queda abrupta de $P_{G,BRUTO}$ é indicado pela segunda linha vertical vermelha tracejada, aos 08m20s. Essa queda foi prevista com um minuto de antecedência pelo algoritmo de previsão de queda de geração, aos 07m20s (primeira linha vertical vermelha tracejada).

Para evitar que o limite de $\Delta P_G/min$ seja ultrapassado, o algoritmo de suavização fornece um novo *set point* ao EMS, com uma variação suavizada de P_G . Dessa forma, a potência fornecida à rede elétrica é ajustada de modo a respeitar os limites impostos a $\Delta P_G/min$.

Ainda na Fig. 52, a diferença de potência entre $P_{G,BRUTO}$ e $P_{G,PREV}$, entre 07m40s e 08m20s, representa a energia que foi armazenada nas baterias ao invés de ter sido exportada à rede. Já a energia entre $P_{G,BRUTO}$ e $P_{G,PREV}$, a partir dos 08m20s em diante, é a energia que foi descarregada das baterias para suavizar a queda de geração.

Na Fig. 53 é ilustrado o $P_{G,SUAV}$, comparado com o $P_{G,BRUTO}$, para o mesmo período entre as linhas tracejadas vermelhas da Fig. 51, entre 08h07m e 08h35m.

Figura 53 – Comparação entre $P_{G,BRUTO}$ e $P_{G,PREV}$, entre 08h07m00s e 08h35m00s do dia 24 de julho de 2023.



Fonte: Autor.

Na Fig. 53, todos os 15 momentos nos quais os limites máximo e mínimo dos $\Delta P_G / mins$ de $P_{G,BRUTO}$ foram ultrapassados, foram suavizados pelo algoritmo de suavização, resultando no $P_{G,SUAV}$.

4.4 Conclusão

Neste trabalho, foi apresentado o desenvolvimento de um método de previsão de curtíssimo prazo de GHI baseada em fotos de ASC, de modo a fornecer informações antecipadas sobre eventos de sombreamento ao algoritmo de suavização da variação abrupta de P_G .

A análise dos resultados da previsão mostrou que o modelo desenvolvido apresentou um erro médio absoluto de 46,751 W/m² para dados inéditos de teste. A magnitude deste erro apresentou esse valor devido principalmente aos GHI s altos, que o modelo possui dificuldades de prever. No entanto, ao observar os gráficos de comparação entre o GHI real e o previsto, nota-se que o modelo tem um bom desempenho para valores médios e baixos de GHI .

A previsão de queda de GHI realizada a partir de fotos de ASC apresentou comportamento satisfatório a partir das análises quantitativas das métricas de desempenho e análises qualitativas dos gráficos, validando a sua utilidade. O uso da previsão foi aplicado em um algoritmo suavizador, demonstrando que a antecipação das quedas de GHI permite que o sistema PV/BESS atue de forma mais eficaz, suavizando as oscilações de potência antes que elas atinjam a rede elétrica.

O algoritmo de suavização de P_G eliminou as 15 violações do limite máximo de

variação de 10% da potência nominal da usina PV/BESS modelada, durante o período analisado. No entanto, para melhorar a sua aplicabilidade, é necessário testar diferentes combinações de janelas deslizantes, incluindo variações de quantidade de passos no passado e previsões para diferentes horizontes no futuro.

A variação dos parâmetros da arquitetura final da rede híbrida também pode ser explorada, incluindo testes de mais e menos camadas convolucionais, LSTM, densas, entre outras, de modo a avaliar o impacto no desempenho da previsão.

A usina experimental está localizada em uma região com alta variabilidade de nebulosidade, na cidade litorânea de João Pessoa/PB. Essa característica, por um lado, é benéfica para o estudo de previsão de sombreamento visto a quantidade de nuvens, mas por outro, provavelmente aumenta o erro da previsão em comparação a locais de pouca nebulosidade, onde há pouca variação do GHI . Portanto, em trabalhos futuros, sugere-se coletar fotos e dados de usinas de grande porte, de modo a testar o desempenho da previsão de GHI em cenários mais representativos, em locais onde usinas PV de grande porte são localizadas.

O algoritmo suavizador foi aplicado a um período de dados para testar a sua usabilidade. No entanto, neste período o uso do BESS foi considerado somente para a suavização de P_G . Ou seja, o uso do BESS para realizar *peak shaving* e *energy arbitrage* foi desconsiderado. Para considerá-lo, é necessário integrar o suavizador de P_G desenvolvido ao otimizador do lucro obtido a partir do despacho do BESS do Capítulo 2, o que pode ser feito em trabalhos futuros.

Este trabalho apresenta uma contribuição significativa para a maximização da participação da energia solar na matriz elétrica, oferecendo uma solução para mitigar os desafios associados à intermitência solar. A integração do método de previsão de GHI com o algoritmo de suavização de P_G permite que usinas PV/BESS operem de forma mais estável, reduzindo as flutuações na rede elétrica. Esta estabilidade é fundamental para superar uma das principais barreiras à adoção em larga escala da energia solar: a preocupação com a confiabilidade e a estabilidade da rede elétrica.

Por fim, conclui-se que o método de previsão de GHI de curtíssimo prazo baseado em fotos de ASC desenvolvido neste trabalho apresenta grande potencial para ser aplicado em sistemas PV/BESS, contribuindo para a suavização da potência fornecida à rede elétrica e, conseqüentemente, melhorando a sua qualidade. Dessa forma, a metodologia proposta oferece uma solução para contribuir com a maximização da participação da energia solar na matriz elétrica, mitigando os impactos ambientais e climáticos da geração de energia.

Referências

ALZHRANI, A. et al. Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, Elsevier, v. 114, p. 304–313, 2017. Citado na página 106.

ANTONANZAS-TORRES, F. et al. *Clear sky solar irradiance models: A review of seventy models*. [S.l.]: Elsevier Ltd, 2019. 374-387 p. Citado na página 101.

BROWNLEE, J. How to develop convolutional neural network models for time series forecasting. *Machine Learning Mastery*, 2018. Acessado em 14-03-2024. Disponível em: <<<https://machinelearningmastery.com/how-to-develop-convolutional-neural-network-models-for-time-series-forecasting/>>>. Citado na página 113.

CHOLLET, F. *Deep learning with Python*. [S.l.]: Manning Publications Co., 2018. Citado na página 109.

DISSAWA, L. H. et al. Sky image-based localized, short-term solar irradiance forecasting for multiple pv sites via cloud motion tracking. *International Journal of Photoenergy*, v. 2021, 2021. ISSN 1687529X. Citado na página 98.

FABEL, Y. et al. *Combining Deep Learning and Physical Models: A Benchmark Study on All-Sky Imager-Based Solar Nowcasting Systems*. [S.l.]: John Wiley and Sons Inc, 2024. Citado na página 95.

GERS, F. A.; SCHMIDHUBER, J.; CUMMINS, F. Learning to forget: Continual prediction with lstm. *Neural computation*, MIT Press, v. 12, n. 10, p. 2451–2471, 2000. Citado na página 108.

GIRASOL. *Girasol, a sky imaging and global solar irradiance dataset - Dryad*. 2021. Disponível em: <<<https://datadryad.org/stash/dataset/doi:10.5061/dryad.zcrjdfn9m>>>. Citado na página 97.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado 2 vezes nas páginas 108 e 110.

GUARISO, G.; NUNNARI, G.; SANGIORGIO, M. Multi-step solar irradiance forecasting and domain adaptation of deep neural networks. *Energies*, MDPI AG, v. 13, 8 2020. ISSN 19961073. Citado na página 96.

- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado 2 vezes nas páginas 106 e 108.
- HOUDT, G. V.; MOSQUERA, C.; NÁPOLES, G. A review on the long short-term memory model. *Artificial Intelligence Review*, Springer Science+Business Media B.V., v. 53, p. 5929–5955, 12 2020. ISSN 15737462. Citado na página 106.
- KAWAGUCHI, K.; KAEHLBLING, L. P.; BENGIO, Y. Generalization in deep learning. 10 2017. Disponível em: <<<http://arxiv.org/abs/1710.05468><http://dx.doi.org/10.1017/9781009025096.003>>>. Citado na página 95.
- Keras Team. *MobileNet and MobileNetV2*. 2023. Acessado em 17-03-2024. Disponível em: <<<https://keras.io/api/applications/mobilenet/>>>. Citado na página 97.
- KHODAYAR, M.; WANG, J. Spatio-temporal graph deep neural network for short-term wind speed forecasting. *IEEE Transactions on Sustainable Energy*, Institute of Electrical and Electronics Engineers Inc., v. 10, p. 670–681, 4 2019. ISSN 19493029. Citado na página 95.
- KUMARI, P.; TOSHNIWAL, D. *Deep learning models for solar irradiance forecasting: A comprehensive review*. [S.l.]: Elsevier Ltd, 2021. Citado 2 vezes nas páginas 95 e 96.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado na página 110.
- LOGOTHETIS, S. A. et al. Benchmarking of solar irradiance nowcast performance derived from all-sky imagers. *Renewable Energy*, v. 199, p. 246–261, 2022. ISSN 18790682. Citado na página 97.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. [S.l.: s.n.], 2010. p. 807–814. Citado na página 112.
- NIJHUM, I. R.; KENNY, P.; DEV, S. Intra-hour solar irradiance estimation using infrared sky images and mobilenetv2-based cnn regression. In: . [S.l.]: Institute of Electrical and Electronics Engineers (IEEE), 2024. p. 3534–3539. ISBN 9798350345094. Citado 2 vezes nas páginas 97 e 118.
- OGLIARI, E.; SAKWA, M.; CUSA, P. Enhanced convolutional neural network for solar radiation nowcasting: All-sky camera infrared images embedded with exogeneous parameters. *Renewable Energy*, Elsevier Ltd, v. 221, 2 2024. ISSN 18790682. Citado 2 vezes nas páginas 97 e 101.

- PALETTA, Q.; ARBOD, G.; LASENBY, J. *Omnivision forecasting: Combining satellite and sky images for improved deterministic and probabilistic intra-hour solar energy predictions*. [S.l.]: Elsevier Ltd, 2023. Citado 2 vezes nas páginas 96 e 118.
- PEREZ, R. et al. *A New Operational Model for Satellite-Derived Irradiances: Description and Validation*. 2002. 307-317 p. Disponível em: <<www.elsevier.com/locate/solener>>. Citado na página 101.
- QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by lstm. *Energy*, Elsevier, v. 148, p. 461–468, 2018. Citado na página 106.
- RYU, A.; ISHII, H.; HAYASHI, Y. Battery smoothing control for photovoltaic system using short-term forecast with total sky images. *Electric Power Systems Research*, Elsevier, v. 190, n. April 2020, p. 106645, jan 2021. ISSN 03787796. Disponível em: <<<https://doi.org/10.1016/j.epsr.2020.106645>>>. Citado na página 98.
- SAGHEER, A.; KOTB, M. Deep learning methods for time series forecasting: Current survey and future directions. *International Journal of Intelligent Systems*, Wiley Online Library, v. 34, n. 8, p. 1636–1657, 2019. Citado na página 110.
- SARKIS, R. et al. Intraday solar irradiance forecasting using public cameras. *Solar Energy*, Elsevier Ltd, v. 275, 6 2024. ISSN 0038092X. Citado 2 vezes nas páginas 97 e 118.
- SCHERER, D.; MÜLLER, A.; BEHNKE, S. Evaluation of pooling operations in convolutional architectures for object recognition. In: SPRINGER. *International conference on artificial neural networks*. [S.l.], 2010. p. 92–101. Citado na página 112.
- WANG, F. et al. Deep learning-based solar radiation prediction. *Energy*, Elsevier, v. 187, p. 115970, 2019. Citado na página 106.
- YEOM, J. M. et al. Spatial mapping of short-term solar radiation prediction incorporating geostationary satellite images coupled with deep convolutional lstm networks for south korea. *Environmental Research Letters*, IOP Publishing Ltd, v. 15, 9 2020. ISSN 17489326. Citado na página 96.
- ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. In: SPRINGER. *European conference on computer vision*. [S.l.], 2014. p. 818–833. Citado na página 111.
- ZHANG, D. et al. Control strategy and optimal configuration of energy storage system for smoothing short-term fluctuation of pv power. *Sustainable Energy Technologies and Assessments*, Elsevier Ltd, v. 45, p. 101166, 2021. ISSN 22131388. Disponível em: <<<https://doi.org/10.1016/j.seta.2021.101166>>>. Citado na página 98.

ZHANG, L.; WANG, S.; LIU, B. Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 8, n. 4, p. e1253, 2018. Citado na página 109.

Capítulo 5

Considerações Finais

Nesta dissertação foi abordada a otimização e integração de novos equipamentos em usinas PVs, especificamente um BESS e uma ASC. A integração destes equipamentos foi considerada desde a sua coleta de dados, a partir da descrição do desenvolvimento dos SCs dos equipamentos, descrito no Capítulo 1. Foram enfrentados e superados desafios relacionados ao cumprimento da norma de monitoramento PV IEC 61724 e à sincronização dos dados obtidos a partir de diferentes fontes.

A integração do BESS permite que a usina PV se torne uma fonte de energia despachável, possibilitando a arbitragem de energia, o corte de pico e a mitigação da intermitência solar. Este tema foi abordado no Capítulo 2, onde foi desenvolvido um método de otimização da projeção da potência do BESS, visando maximizar o lucro diário da usina PV/BESS. A otimização considerou não apenas a maximização do lucro, mas também a preservação da vida útil das baterias e a suavização da potência fornecida à rede elétrica, de modo a reduzir a instabilidade causada pela intermitência solar diária.

O BESS consegue reduzir a intermitência solar diária – não há irradiância solar durante a noite - despachando energia quando necessário. No entanto, a intermitência causada por sombreamento é de difícil previsão por métodos comuns devido à natureza estocástica das nuvens. Para diminuir a intermitência causada por sombreamento, foi desenvolvido um método de previsão de *GHI* a partir das fotos da ASC integrada à usina PV. Essa previsão, desenvolvida no Capítulo 3, possibilita que o BESS atue de maneira antecipada à queda abrupta de *GHI*, de modo que a usina PV/BESS com ASC forneça uma potência elétrica suavizada à rede elétrica.

A integração de BESS e ASC em usinas PV e o desenvolvimento de métodos de previsão e otimização de usinas PV/BESS com ASC, como os desenvolvidos nesta dissertação, tem um papel fundamental na transição energética, visto que eliminam um dos principais desafios associado à fonte solar: a intermitência. Essas soluções permitem

uma maior estabilidade e confiabilidade na geração de energia solar, contribuindo assim para a expansão e integração eficaz da fonte solar na matriz energética, impulsionando a transição para um sistema energético mais sustentável e resiliente.

Referências

AL-MAAITAH, S. S.; AL-MAJALI, H. D. Particle swarm optimizer for bess operation to mitigate voltage deviation of the modified iee 9-bus power system. In: . [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2021. p. 31–36. ISBN 9781665442930. Citado na página 54.

ALI, M. A. et al. *Microgrid Monitoring and Supervision: Web-based SCADA approach*. 2021. Citado na página 31.

ALZAHIRANI, A. et al. Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, Elsevier, v. 114, p. 304–313, 2017. Citado na página 106.

AMMONIT. *Ammonit*. 2023. Disponível em: <<<https://www.ammonit.com/en/products/>>>. Citado na página 35.

ANSI. Preview of iec 61724-1 ed. 2.0 - photovoltaic system performance-part 1: Monitoring. 2021. Citado 3 vezes nas páginas 10, 30 e 46.

ANTONANZAS-TORRES, F. et al. *Clear sky solar irradiance models: A review of seventy models*. [S.l.]: Elsevier Ltd, 2019. 374-387 p. Citado na página 101.

BARBOUR, E.; GONZÁLEZ, M. C. Projecting battery adoption in the prosumer era. *Applied Energy*, v. 215, p. 356–370, 2018. ISSN 03062619. Citado na página 55.

BIASI, C. et al. Sistema fotovoltaico experimental para pesquisas científicas e sua classificação conforme a iec 61724-1 sistema fotovoltaico experimental para pesquisas científicas e sua classificação conforme a iec 61724-1. 2020. Citado na página 29.

BLOOMBERG. *Global Energy Storage Market to Grow 15-Fold by 2030 | BloombergNEF*. 2022. Acessado em 02-07-2023. Disponível em: <<<https://about.bnef.com/blog/global-energy-storage-market-to-grow-15-fold-by-2030/>>>. Citado 2 vezes nas páginas 21 e 53.

BLOOMBERG. *Battery Prices Climb for First Time Just as More EVs Hit Market - Bloomberg*. 2023. Acessado em 02-07-2023. Disponível em: <<<https://www.bloomberg.com/news/articles/2022-12-06/battery-prices-climb-for-first-time-just-as-more-evs-hit-market?leadSource=uverifywall>>>. Citado na página 21.

BROWNLEE, J. How to develop convolutional neural network models for time series forecasting. *Machine Learning Mastery*, 2018. Acessado em 14-03-2024. Disponível em: <<<https://machinelearningmastery.com/how-to-develop-convolutional-neural-network-models-for-time-series-forecasting/>>>. Citado na página 113.

CALLOQUISPE-HUALLPA, R. et al. A comparison between genetic algorithm and particle swarm optimization for economic dispatch in a microgrid. In: . [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2023. p. 415–419. ISBN 9798350336962. Citado na página 53.

CASTRO, N. D.; AMARAL, A.; BRANDÃO, R. *Lições do "apagão" frente à expansão das fontes renováveis no Brasil 1*. 2023. Acessado em 24-06-2024. Disponível em: <<<https://gesel.ie.ufrj.br/artigo-gesel-liceos-do-apagao-frente-a-expansao-das-fontes-renovaveis-no-brasil/>>>. Citado 2 vezes nas páginas 20 e 23.

CCEE. *Painel de Preços - CCEE*. 2022. Acessado em 17-03-2024. Disponível em: <<<https://www.ccee.org.br/web/guest/precos/painel-precos>>>. Citado 3 vezes nas páginas 56, 61 e 72.

CCEE2. *Procedimentos de Comercialização*. <<https://www.ccee.org.br/mercado/procedimentos-de-comercializacao>>. Acessado em 20-06-2024. Citado na página 61.

CHANNEL, N. A. Southeast asia's largest energy storage system opens on jurong island in push for solar power - cna. *CNA*, 2023. Acessado em 20-07-2023. Disponível em: <<<https://www.channelnewsasia.com/singapore/solar-clean-renewable-energy-semcorp-jurong-island-3248671>>>. Citado na página 22.

CHEDDADI, Y. et al. Design and implementation of an intelligent low-cost iot solution for energy monitoring of photovoltaic stations. *SN Applied Sciences*, Springer Nature, v. 2, 7 2020. ISSN 25233971. Citado na página 30.

CHOLLET, F. *Deep learning with Python*. [S.l.]: Manning Publications Co., 2018. Citado na página 109.

CHOW, C. W. et al. Cloud-base height estimation from sky imagery. *Solar Energy*, Elsevier, v. 85, n. 2, p. 329–336, 2011. Citado na página 20.

COINOR. *Interior Point Optimizer - IPOPT*. 2024. Acessado em 17-03-2024. Disponível em: <<<https://github.com/coin-or/Ipopt>>>. Citado na página 59.

- DAS, C. K. et al. Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 91, n. March 2018, p. 1205–1230, aug 2018. ISSN 13640321. Disponível em: <<<https://doi.org/10.1016/j.rser.2018.03.068><https://linkinghub.elsevier.com/retrieve/pii/S1364032118301606>>>. Citado 2 vezes nas páginas 21 e 28.
- DENHOLM, P. et al. Overgeneration from solar energy in california: A field guide to the duck chart. *National Renewable Energy Laboratory*, 2017. Citado na página 20.
- DISSAWA, L. H. et al. Sky image-based localized, short-term solar irradiance forecasting for multiple pv sites via cloud motion tracking. *International Journal of Photoenergy*, v. 2021, 2021. ISSN 1687529X. Citado na página 98.
- DUFFIE, W. A. B. J. A. *Solar Engineering of Thermal Processes, Photovoltaics and Wind*. 2020. Citado na página 44.
- EBERHART, R.; KENNEDY, J. New optimizer using particle swarm theory. *Proceedings of the International Symposium on Micro Machine and Human Science*, p. 39–43, 1995. Citado na página 53.
- EPE. Sistemas de armazenamento em baterias: Aplicações e questões relevantes para o planejamento. *Empresa De Pesquisa Energética (EPE)*, p. 36, 2019. Acessado em 17-03-2024. Disponível em: <<<http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/>>>. Citado na página 20.
- EPE. Empresa de pesquisa energética. estudos do plano decenal de expansão de energia 2030: Parâmetros de custos – geração e transmissão. p. 22, 2021. Acessado em 18-08-2024. Disponível em: <<<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-490/topico-522/CadernodeParâmetrosdeCustos-PDE2030.pdf>>>. Citado 2 vezes nas páginas 20 e 21.
- EPE. *BEN 50 anos*. 2023. Acessado em 17-03-2024. Disponível em: <<<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/Documents/BEN50anos.pdf>>>. Citado na página 23.
- EVANS, A.; STREZOV, V.; EVANS, T. J. Assessment of utility energy storage options for increased renewable energy penetration. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 16, p. 4141–4147, 2012. ISSN 13640321. Acessado em 10-01-2024. Disponível em: <<<http://dx.doi.org/10.1016/j.rser.2012.03.048>>>. Citado 2 vezes nas páginas 20 e 34.

FABEL, Y. et al. *Combining Deep Learning and Physical Models: A Benchmark Study on All-Sky Imager-Based Solar Nowcasting Systems*. [S.l.]: John Wiley and Sons Inc, 2024. Citado na página 95.

GAMS. *GAMS - Cutting Edge Modeling*. 2023. Acessado em 10-11-2023. Disponível em: <<<https://www.gams.com/>>>. Citado na página 54.

GANDOMAN, F. H. et al. Short-term solar power forecasting considering cloud coverage and ambient temperature variation effects. *Renewable Energy*, Elsevier B.V., v. 123, p. 793–805, 2018. ISSN 18790682. Citado na página 21.

GERS, F. A.; SCHMIDHUBER, J.; CUMMINS, F. Learning to forget: Continual prediction with lstm. *Neural computation*, MIT Press, v. 12, n. 10, p. 2451–2471, 2000. Citado na página 108.

GEVORGIAN, V.; MURALI, B.; DAN, T. Interconnection requirements for renewable generation and energy storage in island systems : Puerto rico example preprint interconnection requirements for renewable generation and energy storage in island systems : Puerto rico example preprint. 2019. Citado na página 22.

GIRASOL. *Girasol, a sky imaging and global solar irradiance dataset - Dryad*. 2021. Disponível em: <<<https://datadryad.org/stash/dataset/doi:10.5061/dryad.zcrjdfn9m>>>. Citado na página 97.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado 2 vezes nas páginas 108 e 110.

GUARISO, G.; NUNNARI, G.; SANGIORGIO, M. Multi-step solar irradiance forecasting and domain adaptation of deep neural networks. *Energies*, MDPI AG, v. 13, 8 2020. ISSN 19961073. Citado na página 96.

HAN, J.; LEE, I.; KIM, S. H. User-friendly monitoring system for residential pv system based on low-cost power line communication. *IEEE Transactions on Consumer Electronics*, v. 61, p. 175–180, 2015. ISSN 00983063. Citado na página 31.

HANNAN, M. A. et al. Battery energy-storage system: A review of technologies, optimization objectives, constraints, approaches, and outstanding issues. *Journal of Energy Storage*, Elsevier Ltd, v. 42, p. 103023, 2021. ISSN 2352152X. Disponível em: <<<https://doi.org/10.1016/j.est.2021.103023>>>. Citado 3 vezes nas páginas 20, 21 e 53.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado 2 vezes nas páginas 106 e 108.

HOLLAND, J. H. Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence. *Adaptation*

in *Natural and Artificial Systems*, The MIT Press, 1 1992. Disponível em: <<<https://direct.mit.edu/books/book/2574/Adaptation-in-Natural-and-Artificial-SystemsAn>>>. Citado na página 53.

HOUDT, G. V.; MOSQUERA, C.; NÁPOLES, G. A review on the long short-term memory model. *Artificial Intelligence Review*, Springer Science+Business Media B.V., v. 53, p. 5929–5955, 12 2020. ISSN 15737462. Citado na página 106.

HUAWEI. Solar inverter modbus interface definitions issue 02. 2021. Acessado em 10-05-2022. Disponível em: <<<https://e.huawei.com>>>. Citado 2 vezes nas páginas 39 e 40.

IEA. Net zero by 2050: A roadmap for the global energy sector. *International Energy Agency*, p. 224, 2021. Acessado em 10-08-2023. Disponível em: <<<https://www.iea.org/reports/net-zero-by-2050>>>. Citado na página 36.

IEC. Photovoltaic system performance monitoring-guidelines for measurement, data exchange and analysis - part 1: Monitoring. *Int Stand IEC*, p. 1–10, 2017. Citado 3 vezes nas páginas 29, 30 e 42.

INMET. *Instituto Nacional de Meteorologia - INMET*. 2024. Acessado em 17-03-2024. Disponível em: <<<https://portal.inmet.gov.br/>>>. Citado na página 63.

INTERNATIONAL, B. ‘Europe’s largest’ BESS goes online in UK - Batteries International. 2023. Acessado em 11-09-2022. Disponível em: <<<https://www.batteriesinternational.com/2022/11/24/europes-largest-bess-goes-online-in-uk/>>>. Citado na página 22.

IRENA. Utility-scale batteries innovation landscape brief. *International Renewable Energy Agency*, p. 7, 2019. Acessado em 12-05-2022. Disponível em: <<https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Sep/IRENA_Utility-scale-batteries_2019.pdf>>. Citado na página 22.

JARVELA, M.; LAPPALAINEN, K.; VALKEALAHTI, S. Characteristics of the cloud enhancement phenomenon and pv power plants. *Solar Energy*, Elsevier Ltd, v. 196, p. 137–145, 1 2020. ISSN 0038092X. Citado na página 44.

JEDDI, B.; MISHRA, Y.; LEDWICH, G. Dynamic programming based home energy management unit incorporating pvs and batteries. *IEEE Power and Energy Society General Meeting*, v. 2018-Janua, p. 1–5, 2018. ISSN 19449933. Citado na página 53.

KAWAGUCHI, K.; KAEHLING, L. P.; BENGIO, Y. Generalization in deep learning. 10 2017. Disponível em: <<<http://arxiv.org/abs/1710.05468><http://dx.doi.org/10.1017/9781009025096.003>>>. Citado na página 95.

- Keras Team. *MobileNet and MobileNetV2*. 2023. Acessado em 17-03-2024. Disponível em: <<<https://keras.io/api/applications/mobilenet/>>>. Citado na página 97.
- KHODAYAR, M.; WANG, J. Spatio-temporal graph deep neural network for short-term wind speed forecasting. *IEEE Transactions on Sustainable Energy*, Institute of Electrical and Electronics Engineers Inc., v. 10, p. 670–681, 4 2019. ISSN 19493029. Citado na página 95.
- KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering and System Safety*, v. 91, p. 992–1007, 9 2006. ISSN 09518320. Citado na página 58.
- KUMARI, P.; TOSHNIWAL, D. *Deep learning models for solar irradiance forecasting: A comprehensive review*. [S.l.]: Elsevier Ltd, 2021. Citado 2 vezes nas páginas 95 e 96.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado na página 110.
- LI, P.-N. *GitHub - liponan/sxccd-python: Python API for Startlight Xpress CCD (sxccd)*. 2023. Acessado em 07-06-2022. Disponível em: <<<https://github.com/liponan/sxccd-python>>>. Citado na página 40.
- LOGOTHETIS, S. A. et al. Benchmarking of solar irradiance nowcast performance derived from all-sky imagers. *Renewable Energy*, v. 199, p. 246–261, 2022. ISSN 18790682. Citado na página 97.
- LOPES, A. D. C. et al. Avaliação de desempenho de tecnologias emergentes para controle de tensão em redes de distribuição com elevada penetração de microgeração fotovoltaica. 2020. Citado na página 54.
- LUND, P. D. et al. Review of energy system flexibility measures to enable high levels of variable renewable electricity. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 45, p. 785–807, 2015. Citado na página 20.
- MADETI, S. R.; SINGH, S. N. Monitoring system for photovoltaic plants: A review. *Renewable and Sustainable Energy Reviews*, v. 67, p. 1180–1207, 2017. ISSN 18790690. Citado na página 30.
- MARTIRANO, L. et al. Implementation of scada systems for a real microgrid lab testbed. *2019 IEEE Milan PowerTech, PowerTech 2019*, IEEE, p. 1–6, 2019. Citado na página 31.
- MINIO. *Optimize Snowflake Architecture with MinIO*. 2023. Acessado em 10-05-2022. Disponível em: <<<https://min.io/solutions/>>>. Citado na página 41.
- MODBUS. Modbus application protocol specification v1.1b3 modbus. 2012. Acessado em 10-02-2022. Disponível em: <<<http://www.modbus.org>>>. Citado na página 37.

- MOHAMED, A. A. R. et al. A Comprehensive Robust Techno-Economic Analysis and Sizing Tool for the Small-Scale PV and BESS. *IEEE Transactions on Energy Conversion*, IEEE, v. 37, n. 1, p. 560–572, mar 2022. ISSN 0885-8969. Disponível em: <<<https://ieeexplore.ieee.org/document/9521731/>>>. Citado na página 69.
- MONTOYA, O. D.; GIL-GONZÁLEZ, W.; GRISALES-NOREÑA, L. F. An exact minlp model for optimal location and sizing of dgs in distribution networks: A general algebraic modeling system approach. *Ain Shams Engineering Journal*, Faculty of Engineering, Ain Shams University, v. 11, p. 409–418, 2020. ISSN 20904479. Disponível em: <<<https://doi.org/10.1016/j.asej.2019.08.011>>>. Citado na página 55.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. [S.l.: s.n.], 2010. p. 807–814. Citado na página 112.
- NDUKWE, C.; IQBAL, M. T.; KHAN, J. Development of a low-cost lora based scada system for monitoring and supervisory control of small renewable energy generation systems. *11th Annual IEEE Information Technology, Electronics and Mobile Communication Conference, IEMCON 2020*, p. 479–484, 2020. Citado na página 31.
- NIJHUM, I. R.; KENNY, P.; DEV, S. Intra-hour solar irradiance estimation using infrared sky images and mobilenetv2-based cnn regression. In: . [S.l.]: Institute of Electrical and Electronics Engineers (IEEE), 2024. p. 3534–3539. ISBN 9798350345094. Citado 2 vezes nas páginas 97 e 118.
- OGLIARI, E.; SAKWA, M.; CUSA, P. Enhanced convolutional neural network for solar radiation nowcasting: All-sky camera infrared images embedded with exogeneous parameters. *Renewable Energy*, Elsevier Ltd, v. 221, 2 2024. ISSN 18790682. Citado 2 vezes nas páginas 97 e 101.
- OLIVEIRA, L. M. et al. Gerenciamento Ótimo de energia elétrica para maximização de lucro de uma planta fotovoltaica com baterias. In: . [S.l.]: SBA Sociedade Brasileira de Automática, 2022. Citado na página 74.
- OPENDSS. *Open Distribution System Simulator*. 2023. Acessado em 17-03-2024. Disponível em: <<<https://www.epri.com/pages/sa/openss>>>. Citado 2 vezes nas páginas 54 e 55.
- OSORIO, D. M. A review in bess optimization for power systems. p. 1–32, 2023. Citado 3 vezes nas páginas 10, 53 e 54.
- PALETTA, Q.; ARBOD, G.; LASENBY, J. *Omnivision forecasting: Combining satellite and sky images for improved deterministic and probabilistic intra-hour solar energy predictions*. [S.l.]: Elsevier Ltd, 2023. Citado 2 vezes nas páginas 96 e 118.

- PEREZ, R. et al. *A New Operational Model for Satellite-Derived Irradiances: Description and Validation*. 2002. 307-317 p. Disponível em: <<www.elsevier.com/locate/solener>>. Citado na página 101.
- PYMODBUSTCP. *Welcome to pyModbusTCP's documentation — pyModbusTCP 0.2.0 documentation*. 2023. Acessado em 22-02-2022. Disponível em: <<<https://pymodbustcp.readthedocs.io/en/latest/>>>. Citado na página 38.
- PYOMO. *Pyomo - Python Optimization Modeling*. 2023. Acessado em 12-05-2023. Disponível em: <<<http://www.pyomo.org/>>>. Citado na página 54.
- QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by lstm. *Energy*, Elsevier, v. 148, p. 461–468, 2018. Citado na página 106.
- RAINVILLE, F. M. D. et al. Deap: A python framework for evolutionary algorithms. *GECCO'12 - Proceedings of the 14th International Conference on Genetic and Evolutionary Computation Companion*, Association for Computing Machinery, p. 85–92, 2012. Citado na página 58.
- ROSS, R. G. Design techniques for flat-plate photovoltaic arrays. In: *Proceedings of the 15th IEEE Photovoltaic Specialists Conference*. [S.l.: s.n.], 1986. Citado na página 64.
- RYU, A.; ISHII, H.; HAYASHI, Y. Battery smoothing control for photovoltaic system using short-term forecast with total sky images. *Electric Power Systems Research*, Elsevier, v. 190, n. April 2020, p. 106645, jan 2021. ISSN 03787796. Disponível em: <<<https://doi.org/10.1016/j.epsr.2020.106645>>>. Citado na página 98.
- SAGHEER, A.; KOTB, M. Deep learning methods for time series forecasting: Current survey and future directions. *International Journal of Intelligent Systems*, Wiley Online Library, v. 34, n. 8, p. 1636–1657, 2019. Citado na página 110.
- SALEH, M. et al. Battery-less short-term smoothing of photovoltaic generation using sky camera. *IEEE Transactions on Industrial Informatics*, IEEE, v. 14, p. 403–414, 2018. ISSN 15513203. Citado na página 20.
- SARKIS, R. et al. Intraday solar irradiance forecasting using public cameras. *Solar Energy*, Elsevier Ltd, v. 275, 6 2024. ISSN 0038092X. Citado 2 vezes nas páginas 97 e 118.
- SCHERER, D.; MÜLLER, A.; BEHNKE, S. Evaluation of pooling operations in convolutional architectures for object recognition. In: SPRINGER. *International conference on artificial neural networks*. [S.l.], 2010. p. 92–101. Citado na página 112.
- SOROUDI, A. *Power system optimization modeling in GAMS*. [S.l.]: Springer International Publishing, 2017. 1-295 p. ISBN 9783319623504. Citado na página 55.

SOROUDI, A. *DEDESSwind : Cost based Dynamic Economic Dispatch integrated with Energy Storage and Wind*. 2023. Acessado em 17-03-2024. Disponível em: <<https://www.gams.com/latest/psoptlib_ml/libhtml/psoptlib_DEDESSwind.html>>. Citado na página 55.

SOTO, W. D.; KLEIN, S. A.; BECKMAN, W. A. Improvement and validation of a model for photovoltaic array performance. *Solar Energy*, Elsevier Ltd, v. 80, p. 78–88, 2006. ISSN 0038092X. Citado na página 64.

STARLIGHT. *Starlight Xpress Oculus All Sky Camera with 150 Degree Fish Eye Lens / OPT Telescopes*. 2024. Acessado em 20-04-2022. Disponível em: <<<https://optcorp.com/collections/starlight-xpress/products/sx-oculus-all-sky-camera>>>. Citado na página 40.

SUKUMAR, S. et al. Ramp-rate control smoothing methods to control output power fluctuations from solar photovoltaic (pv) sources—a review. *Journal of Energy Storage*, Elsevier, v. 20, p. 218–229, 2018. ISSN 2352152X. Disponível em: <<<https://doi.org/10.1016/j.est.2018.09.013>>>. Citado na página 22.

SWIERCZYNSKI, M. et al. Lifetime estimation of the nanophosphate lifepo4/c battery chemistry used in fully electric vehicles. *IEEE Transactions on Industry Applications*, Institute of Electrical and Electronics Engineers Inc., v. 51, p. 3453–3461, 7 2015. ISSN 00939994. Citado na página 74.

SYED, M. A.; KHALID, M. Machine learning based controlled filtering for solar pv variability reduction with bess. *2021 International Conference on Sustainable Energy and Future Electric Transportation, SeFet 2021*, p. 0–4, 2021. Citado na página 21.

WANG, F. et al. Deep learning-based solar radiation prediction. *Energy*, Elsevier, v. 187, p. 115970, 2019. Citado na página 106.

WU, C.; ZHANG, X. P.; STERLING, M. Solar power generation intermittency and aggregation. *Scientific Reports*, Nature Publishing Group UK, v. 12, p. 1–12, 2022. ISSN 20452322. Disponível em: <<<https://doi.org/10.1038/s41598-022-05247-2>>>. Citado na página 20.

YEOM, J. M. et al. Spatial mapping of short-term solar radiation prediction incorporating geostationary satellite images coupled with deep convolutional lstm networks for south korea. *Environmental Research Letters*, IOP Publishing Ltd, v. 15, 9 2020. ISSN 17489326. Citado na página 96.

ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. In: SPRINGER. *European conference on computer vision*. [S.l.], 2014. p. 818–833. Citado na página 111.

ZHANG, D. et al. Control strategy and optimal configuration of energy storage system for smoothing short-term fluctuation of pv power. *Sustainable Energy Technologies and Assessments*, Elsevier Ltd, v. 45, p. 101166, 2021. ISSN 22131388. Disponível em: <<<https://doi.org/10.1016/j.seta.2021.101166>>>. Citado na página 98.

ZHANG, L.; WANG, S.; LIU, B. Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 8, n. 4, p. e1253, 2018. Citado na página 109.

ZIA, M. F.; ELBOUCHIKHI, E.; BENBOUZID, M. Optimal operational planning of scalable DC microgrid with demand response, islanding, and battery degradation cost considerations. *Applied Energy*, Elsevier, v. 237, n. October 2018, p. 695–707, mar 2019. ISSN 03062619. Disponível em: <<<https://doi.org/10.1016/j.apenergy.2019.01.040><https://linkinghub.elsevier.com/retrieve/pii/S0306261919300406>>>. Citado na página 55.