UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO

LEONARDO ROSA SCOPEL

PREVISÃO DE POTÊNCIA POR REDES NEURAIS E GERENCIAMENTO DE ENERGIA ELÉTRICA POR META-HEURÍSTICA DE UMA MICRORREDE IMPLEMENTADA EM UM ESTACIONAMENTO INTELIGENTE

VITÓRIA
2020

LEONARDO ROSA SCOPEL

PREVISÃO DE POTÊNCIA POR REDES NEURAIS E GERENCIAMENTO DE ENERGIA ELÉTRICA POR META-HEURÍSTICA DE UMA MICRORREDE IMPLEMENTADA EM UM ESTACIONAMENTO INTELIGENTE

Parte manuscrita do Projeto de Graduação do aluno **Leonardo Rosa Scopel**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientadora: Profa. Dra. Jussara Farias Fardin
Coorientador: Prof. Dr. Helder Roberto de Oliveira Rocha

VITÓRIA
2020

LEONARDO ROSA SCOPEL

PREVISÃO DE POTÊNCIA POR REDES NEURAIS E GERENCIAMENTO DE ENERGIA ELÉTRICA POR META-HEURÍSTICA DE UMA MICRORREDE IMPLEMENTADA EM UM ESTACIONAMENTO INTELIGENTE

Parte manuscrita do Projeto de Graduação do aluno **Leonardo Rosa Scopel** apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovada em 15 de dezembro de 2020.

COMISSÃO EXAMINADORA:

Jussara Farias Fardin

Profa. Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo
Orientadora

Helder Roberto de O. Rocha

Prof. Dr. Helder Roberto de Oliveira Rocha
Universidade Federal do Espírito Santo
Coorientador

Prof. Dr. Augusto César Rueda Medina
Universidade Federal do Espírito Santo
Examinador

Lucas Frizera Encarnação

Prof. Dr. Lucas Frizera Encarnação
Universidade Federal do Espírito Santo
Examinador

Ao meu avô Alfredo.

AGRADECIMENTOS

À Mãe Terra pela existência e saúde.

Aos meus pais, Profa. Dra. Edinete Maria Rosa e Prof. Dr. Wanderlã Luis Scopel, por terem me oportunizado ao longo de toda a vida acesso irrestrito ao conhecimento e serem minha fonte de inspiração acadêmica.

À minha família, em particular minhas irmãs Lívia Helena e Ana Beatriz, pelo apoio e incentivo.

Aos meus orientadores Profa. Dra. Jussara Farias Fardin e Prof. Dr. Helder Roberto de Oliveira Rocha, pela paciência, atenção e ensinamentos ao longo desse trabalho.

À Universidade Federal do Espírito Santo, por oferecer no Brasil ensino público de excelência.

RESUMO

Neste trabalho, apresenta-se uma proposta para o problema de despacho de energia que consiste na previsão e gerenciamento energético diário de um estacionamento inteligente, com o objetivo principal de encontrar o melhor planejamento de armazenamento de energia para os veículos elétricos, minimizando o custo total da energia comprada pela microrrede da rede de distribuição. O fluxo de potência entre o estacionamento e os veículos é bidirecional, podendo os mesmos atuarem tanto como carga quanto como unidades de armazenamento. A demanda é pré-determinada, tendo os veículos prioridade de carregamento, horário de chegada e saída e estado de carga da bateria na chegada e saída do estacionamento. Utilizando uma base de dados meteorológicos e modelos matemáticos de uma turbina eólica e painéis fotovoltaicos, foram geradas potências correlatas. Estas serviram como dados de entrada para o treinamento de redes neurais artificiais, desenvolvidas em *Python* na plataforma *Google Colab*, que predisseram com 24 horas de antecedência a potência gerada para ser utilizada na otimização do estacionamento inteligente. As redes de unidade de memória de longo-curto prazo (LSTM, do inglês *long short-term memory*) obtiveram 94,04% e 92,9% de eficiência na predição da potência solar e eólica, respectivamente; e o algoritmo de busca gravitacional (GSA, do inglês *gravitacional search algorithm*) com função mono-objetivo, desenvolvido no *software MatLab*, obteve resultado satisfatório na otimização de despacho de energia, atendendo às restrições do sistema.

Palavras-chave: Microrrede. Estacionamento inteligente. Metaheurística. Rede neural recorrente. Veículos elétricos. Fontes renováveis. Despacho de energia.

ABSTRACT

This work presents a method for the power dispatching problem that consists of a daily energy forecast and management of a smart park. The main goal is to find the best energy storage planning for plug-in electric vehicles, minimizing the total microgrid purchase cost. The electric vehicles and the smart park has a bidirectional power flow, so the vehicles can act as storage units or loads. The demand is pre-supplied, so the vehicles have the following specifications: charging priority, arrival and departure time, and battery state of charge on arrival and departure from the smart park. Using a meteorological database was implemented a mathematical modulation of a wind turbine and photovoltaic panels, in order to generate renewable electric energy. A long short-term memory recurrent network (LSTM) was proposed to forecast the output power of photovoltaic panels and wind turbines and achieved respectively 94.04% and 92.9% of accuracy in prediction, developed in Python on Google Colab. A metaheuristics gravitational search algorithm (GSA), developed on MatLab, with mono-objective function, was used for optimizing the energy dispatch and the proposed approach obtained a satisfactory result, supplying the demand specifications.

Keywords: Micro grids. Smart park. Metaheuristics. Recurrent neural network. Plug-in electric vehicles. Renewable sources. Energy dispatching.

LISTA DE FIGURAS

Figura 1 – Diagrama da microrrede: o estacionamento inteligente 19
Figura 2 – Processo hierarquizado de agrupamento 26
Figura 3 – Bloco de memória LSTM 33
Figura 4 – Espaço de busca gravitacional 35
Figura 5 – Fluxograma do GSA 37
Figura 6 – Fluxograma da lógica de funcionamento do banco de baterias 42
Figura 7 – População inicial do GSA 43

LISTA DE GRÁFICOS

Gráfico 1 – Emissões globais de CO_2 resultantes do uso de combustíveis fósseis, em gigatoneladas 16
Gráfico 2 – Produção global de energia elétrica, 2019 17
Gráfico 3 – Curva de potência: controle *stall* 24
Gráfico 4 – Curva de potência: controle por passo 24
Gráfico 5 – Curvas I x V e P x V do módulo fotovoltaico: parâmetros de potência máxima 27
Gráfico 6 – Influência da radiação solar e temperatura na curva I x V do módulo fotovoltaico 29
Gráfico 7 – Curva de potência eólica real e modelada 39
Gráfico 8 – Perda da rede neural na predição da potência solar 45
Gráfico 9 – Perda da rede neural na predição da potência eólica 46
Gráfico 10 – Comparação entre potência solar real e predita 46
Gráfico 11 – Comparação entre potência eólica real e predita 47
Gráfico 12 – Desempenho dos indivíduos ao longo das gerações 48
Gráfico 13 – Penalização por estado de carga final insuficiente dos veículos elétrico ao longo das gerações 48
Gráfico 14 – Estado de carga do banco de baterias ao longo das 24 horas 49
Gráfico 15 – Estado de carga dos veículos PEV1, PEV2, PEV3 e PEV4 ao longo das 24 horas 50

LISTA DE QUADROS

Quadro 1 – Fator de rugosidade em função do tipo de terreno 23
Quadro 2 – Dados do banco de baterias do SP..... 31
Quadro 3 – Características técnicas dos veículos elétricos 32
Quadro 4 – Especificações técnicas adaptado do gerador eólico Enersud Verne 555..... 39
Quadro 5 – Coeficientes do polinômio da curva de potência..... 39
Quadro 6 – Especificações técnicas do painel fotovoltaico *Canadian Solar* CS6P-260..... 40
Quadro 7 – Arquitetura da rede neural..... 41
Quadro 8 – Demanda do SP 41
Quadro 9 – Indivíduo do GSA..... 43
Quadro 10 – Valor da energia fornecida pela concessionária 44

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
CRESESB	Centro de Referência para as Energias Solar e Eólica Sérgio de Salvo Brito
GD	Geração Distribuída
GSA	*Gravitational Search Algorithm*
IEA	*International Energy Agency*
LSTM	*Long Short-Term Memory*
PEV	*Plug-in Electric Vehicle*
PV	*Photovoltaic Panel*
RMSE	*Root Mean Square Error*
RNN	*Recurrent Neural Network*
SG	*Smart Grid*
SOC	*State of Charge*
TE	Tarifa de Energia
TUSD	Tarifa de Uso do Sistema de Distribuição
UFES	Universidade Federal do Espírito Santo

LISTA DE SÍMBOLOS

V	Velocidade do vento (m/s)
V_1	Velocidade do vento na altura conhecida (m/s)
H	Altura desejada (m)
H_1	Altura conhecida (m)
n	Fator de rugosidade do terreno
P_e	Potência extraída pela turbina (W)
A	Área de varredura das pás da turbina (m²)
ρ	Densidade do ar (kg/m³)
C_p	Coeficiente de potência
Np	Grau do polinômio utilizado para a curva de potência da turbina eólica
V_i	Velocidade do vento de partida de operação da turbina eólica (m/s)
V_o	Velocidade do vento máxima de operação da turbina eólica (m/s)
a_i	Coeficiente do polinômio da curva de potência da turbina eólica
P_f	Potência gerada pelo módulo fotovoltaico (W)
η	Rendimento do painel fotovoltaico
r	Irradiação solar (W/m²)
S	Área do painel fotovoltaico (m²)
Npv	Número de painéis fotovoltaicos;
T_c	Temperatura do painel fotovoltaico (°C)
T_a	Temperatura do ambiente (°C)
N_{ot}	Temperatura nominal de operação da célula (°C)
I	Corrente na célula (A)
I_{sc}	Corrente de curto circuito da célula (A)
K_i	Coeficiente de corrente/temperatura (A/°C)
Vpv	Tensão no módulo fotovoltaico (V)
V_{oc}	Tensão de circuito aberto do módulo (V)
K_v	Coeficiente de tensão/temperatura (V/°C)
FF	Fator de forma
V_{mppt}	Tensão no ponto de máxima potência (V)
I_{mppt}	Corrente no ponto de máxima potência (A)
SOC	Estado de carga da bateria (kWh)

SOC_{min}	Estado de carga mínimo da bateria (kWh)
SOC_{max}	Estado de carga máximo da bateria (kWh)
N_{ev}	Número de carregadores
Pev	Taxa de carregamento do carro elétrico (kW)
Pev^{max}	Taxa máxima de carregamento do carro elétrico (kW)
t	Intervalo de tempo (s)
Δ	Variação na taxa de carregamento do carro elétrico (kW)
c	Estado da unidade de memória
i	Portão de entrada
f	Portão de esquecimento
o	Portão de saída
x	Dado da camada X
h	Dado da camada H
b	Constante *bias*
W	Peso do estado da memória
σ	Função de ativação
x_i	Valor da variável predita
x_o	Valor da variável observada
n_a	Número de observações para análise
j	Massa j
N	Número de agentes
x	Posição do agente
d	Dimensão do agente
a	Aceleração
F	Força gravitacional
M_a	Massa gravitacional ativa
M_p	Massa gravitacional passiva
M_i	Massa gravitacional inercial
G	Constante gravitacional
R	Distância Euclidiana
€	Constante força entre massas
v	Velocidade do agente
fit	Função objetivo

C_{ec}	Custo energia comprada (R$)
C_{ev}	Custo energia vendida (R$)
k_e	Peso custo da energia
C_{soc}	Contador de penalização para SOC menor que o demandado
k_{soc}	Peso SOC insuficiente
D_{soc}	Peso para diferença entre SOC e SOC demandado
E_c	Energia comprada (kWh)
E_v	Energia vendida (kWh)
$R\$_{fponta}$	Valor da energia em horário fora ponta (R$/kWh)
$R\$_i$	Valor da energia em horário intermediário (R$/kWh)
$R\$_{ponta}$	Valor da energia em horário ponta (R$/kWh)

SUMÁRIO

1 INTRODUÇÃO 16

1.1 Apresentação **16**

1.2 Justificativa **19**

1.3 Objetivos **20**

1.3.1 Objetivo Geral 20

1.3.2 Objetivos Específicos 20

1.4 Organização do Trabalho **21**

2 EMBASAMENTO TEÓRICO 22

2.1 Microrredes **22**

2.2 Turbina Eólica **22**

2.2.1 Velocidade do Vento 22

2.2.2 Controle de *Stall* e Controle de Passo 23

2.2.3 Modelagem da Turbina Eólica 25

2.3 Painel Fotovoltaico **26**

2.3.1 Ponto de Máxima Potência 27

2.3.2 Modelagem do Painel Fotovoltaico 28

2.4 Armazenamento de Energia Elétrica **30**

2.5 Veículos Elétricos **31**

2.6 Redes Neurais Recorrentes **32**

2.7 Metaheurísticas de Busca Gravitacional **34**

3 ESTACIONAMENTO INTELIGENTE 38

3.1 Dados Históricos e Organização da Base de Dados **38**

3.2 Predição de Potência Gerada **38**

3.2.1 Caracterização do Aerogerador 38

3.2.2 Caracterização do Painel Fotovoltaico 40

3.2.3 Caracterização da Rede Neural 40

3.3 Definição da Demanda **41**

3.4 Funcionamento do Banco de Baterias **42**

3.5 Codificação da Solução **42**

4 RESULTADOS E DISCUSSÕES 45

4.1 Métrica de Validação da LSTM 45
4.2 Comparação entre Potência Real e Predita..... 46
4.3 Análise do Otimizador 47

5 CONCLUSÕES E TRABALHOS FUTUROS..... 51

REFERÊNCIAS BIBLIOGRÁFICAS..... 52

1 INTRODUÇÃO

1.1 Apresentação

Em 2020, o COVID-19 está transformando a vida de todos os humanos com privação de liberdade social, recessão econômica global e mais de um milhão de mortes. O vírus está sendo devastador para os seres humanos, mas as consequências das mudanças climáticas serão ainda mais impactantes e durarão muito mais tempo. Neste sentido, a necessidade de mudar a matriz energética para fontes carbono-zero é imprescindível para o equilíbrio ecológico e econômico do planeta. Objetivamente, deve-se focar em três principais diretrizes: liderar-se pela ciência e inovação, garantir que soluções funcionem em países pobres e começar hoje (GATES, 2020).

No Gráfico 1, apresenta-se as emissões de dióxido de carbono (CO_2) associadas à geração de energia por combustíveis fósseis que, exceto pelo ano de 2018, a emissão de CO_2 aumentou ao longo dos anos. No Gráfico 2, a matriz energética global é mostrada evidenciando os combustíveis não-renováveis e emissores de CO_2 como principais fontes na geração de energia elétrica no planeta.

Gráfico 1 – Emissões globais de CO_2 resultantes do uso de combustíveis fósseis, em gigatoneladas

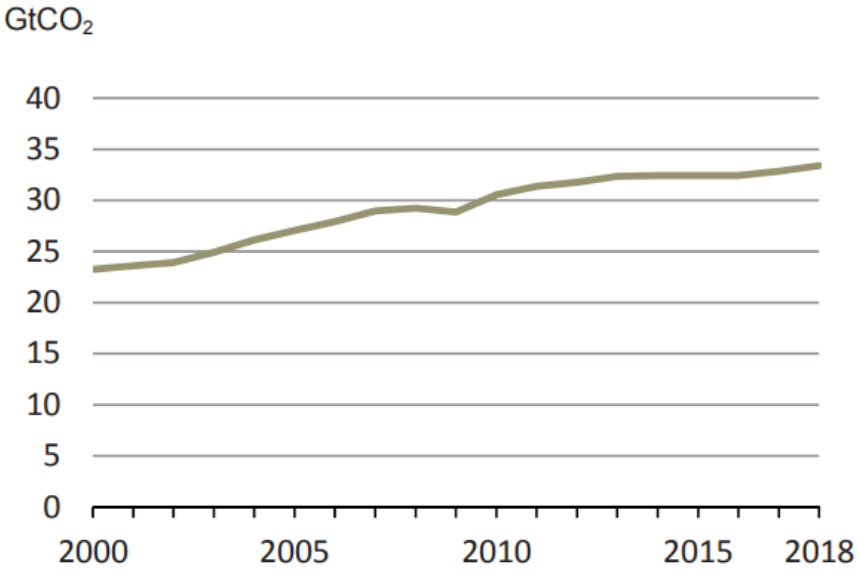

Fonte: *International Energy Agency* (2019).

Gráfico 2 – Produção global de energia elétrica, 2019

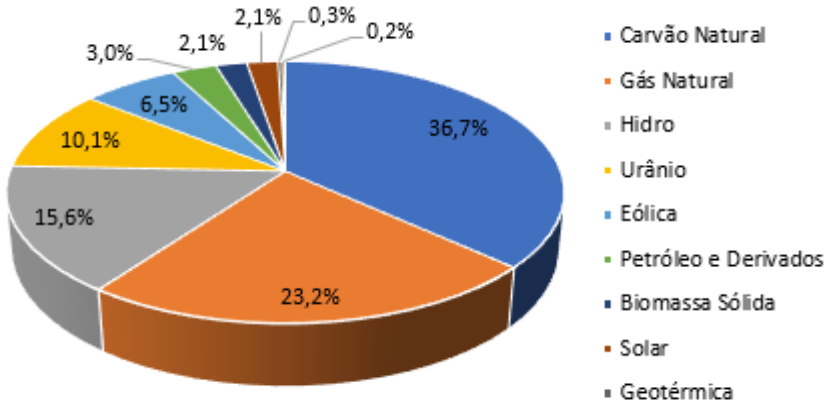

Fonte: Resenha Energética Brasileira (2020).
Nota: Adaptado pelo autor.

A pandemia mostrou o quanto a humanidade precisa ser inovadora para evitar catástrofes humanitárias, e terá que ser novamente para suprir as necessidades energéticas utilizando fontes com zero emissão de carbono. No entanto, mesmo com notório avanço, as tecnologias precisam ser mais baratas do que são hoje, ou seja, serem competitivas em relação aos combustíveis fósseis e produzidas em escala. Neste trabalho, propõe-se contribuir em três frentes promissoras: fontes energéticas com zero emissão de carbono, infraestrutura para veículos elétricos e rede elétrica eficiente.

Começando pela última, a descentralização da geração de energia sugere que cargas longe da fonte, com longas linhas de transmissão em corrente alternada, e um grande sistema elétrico, dificultam o gerenciamento ótimo de energia, com perdas desnecessárias e poucas informações dos processos. Neste sentido, define-se microrrede como um sistema autônomo de energia composto do conjunto de unidades geradoras e múltiplas cargas elétricas, podendo operar no modo ilhado ou conectado à rede (ASMUS, 2010). Assim, tem-se um sistema de energia confiável, flexível e eficiente, além de ser intrínseco em sua concepção o uso de fontes de energia renováveis.

Porém, a característica intermitente da geração fotovoltaica e eólica, utilizadas como fontes energéticas na microrrede deste trabalho, impõe outro desafio. Como armazenar energia elétrica?

As baterias tiveram 85% de queda em seu valor de mercado desde 2010 (GATES, 2020), entretanto continuam grandes e pesadas. Pela ótica do transporte é desastroso, pois quanto mais peso tenta-se mover, mais baterias precisam ser adicionadas. Assim, para aumentar a eficiência no uso das baterias aplica-se gerenciamento ótimo de energia.

A microrrede deste trabalho, desenvolvida no *software MatLab* e esquematizada na Figura 1, atenderá um estacionamento inteligente (SP, do inglês *smart park*) com carregadores elétricos, composta por fontes renováveis, banco de baterias e frota de veículos elétricos (PEV, do inglês *plug-in electric vehicle*), que tem por objetivo prover o melhor planejamento de armazenamento de energia para os veículos e banco de baterias ao longo de um dia. Utilizando a base de dados da estação meteorológica localizada no Campus de São Mateus da Universidade Federal do Espírito Santo (UFES), treina-se uma rede neural, desenvolvida em *Python* na plataforma *Google Colab*, para predizer a potência gerada, para que os resultados e análises do sistema ocorram com 24 horas de antecedência.

O sistema possuirá dez carros e quatro carregadores e a demanda será definida no início do ciclo diário contendo: a prioridade do veículo em relação aos demais, horário de chegada e saída; e o estado de carga da bateria dos veículos (SOC, do inglês *state of charge*) na chegada e o desejado na saída do SP. O fluxo de potência entre o carro e o estacionamento é bidirecional, podendo o PEV atuar como carga ou unidade de armazenamento de energia.

O trabalho realizado nessa monografia possui como procedimento metodológico a pesquisa experimental, isto é, com o objetivo exploratório, foram testadas hipóteses e manipuladas variáveis, pautadas na literatura dos temas correlatos, para análise dos resultados e conclusões. A natureza da metodologia é de aplicação, por engenhar e simular o sistema em estudo, avaliando quantitativamente e qualitativamente as variáveis, para observar a relação entre causas e efeitos.

Figura 1 – Diagrama da microrrede: o estacionamento inteligente

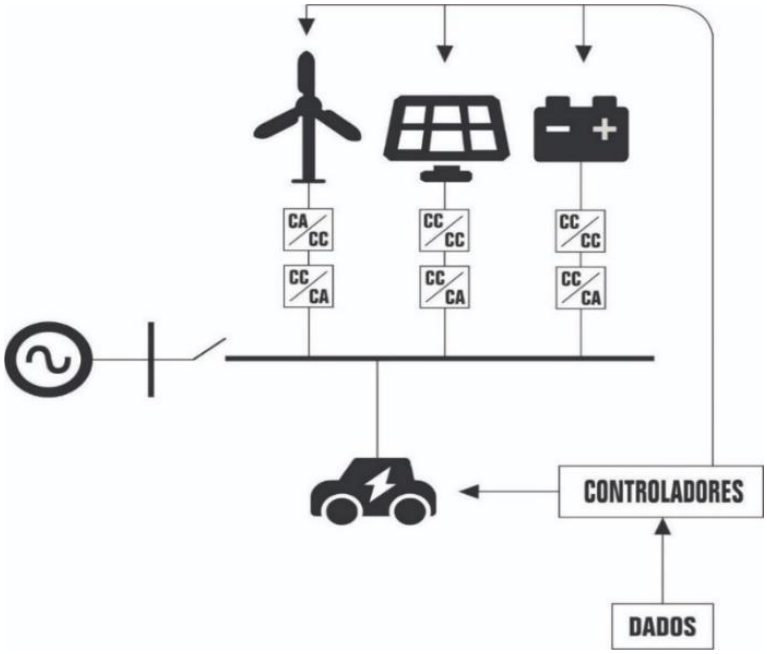

Fonte: Produzido pelo próprio autor.

1.2 Justificativa

A utilização de redes neurais recorrentes para a predição de potência de painéis fotovoltaicos é estudada por Wang, Qi e Liu (2019), assim como por Zhao e outros (2014), constatando-se a acurácia dessa abordagem para a predição de potência de fontes dependentes de longas séries temporais.

O tempo de carregamento de veículos elétricos possui a particularidade de ter como limitante operacional as perdas joulicas. Assim, o conceito hoje existente de posto de combustível para veículos a combustão não faz sentido quando aplicados a PEV, pois fisicamente é natural que o carregamento do carro elétrico demande mais tempo, para se evitar perdas. Por isso, o estacionamento inteligente desenvolvido neste trabalho é um modelo de microrrede atrativo e realista, podendo ser implementado em indústrias, fazendas e mercados.

Recentemente, Alves e outros (2019) apresentaram uma otimização dinâmica evolucionária para despacho de energia em uma microrrede usando veículos elétricos. Coelho e outros (2016) abordaram o problema de despacho de energia em uma microrrede a partir de uma visão

multiobjetivo e programação linear utilizando variáveis inteiras mistas (do inglês, *mixed-integer linear programming*) para o plano de armazenamento de energia.

Assim, este trabalho contribui para a análise do desempenho das redes neurais recorrentes aplicadas à predição de geração distribuída, energia eólica e solar. Metaheurísticas são avaliadas quanto à utilização para a otimização do problema de despacho de energia, com função mono-objetivo, e a proposição de modelos e metodologias para a infraestrutura de carregamento dos veículos elétricos fomenta o desenvolvimento de soluções para a área.

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver um modelo computacional de estacionamento inteligente que encontre o melhor planejamento de armazenamento de energia para veículos ao longo de um dia.

1.3.2 Objetivos Específicos

Os objetivos específicos do trabalho são:

a) Modelar matematicamente painel fotovoltaico, turbina eólica, veículos elétricos e banco de baterias;
b) Predizer a potência gerada pela microrrede com 24 horas de antecedência;
c) Desenvolver o gerenciamento energético do SP para atender as demandas operacionais;
d) Aferir o desempenho do otimizador para o modelo de codificação da solução e função de avaliação.

Atingindo-se os objetivos, tem-se um sistema inteligente e economicamente atrativo, que fomenta o conhecimento em tecnologias que promovem fontes de energia elétrica sustentável e infraestrutura para veículos elétricos.

1.4 Organização do Trabalho

O trabalho foi dividido em 5 seções e os parágrafos a seguir introduzem o assunto abordado por cada um deles.

Na seção 2 é apresentada uma revisão bibliográfica sobre as temáticas correlatas ao projeto de graduação. A seção começa apresentando no estado da arte o conceito de microrrede e em seguida descreve os modelos matemáticos das fontes de energia elétrica utilizadas no trabalho. Posteriormente, o sistema de armazenamento de energia e dos veículos elétricos, e por fim, os algoritmos utilizados para a predição de potência e otimização do SP.

Na seção 3, descreve-se a metodologia usada para implementar o estacionamento inteligente, assim como a sua caracterização e dimensionamento. Também é especificada a demanda pré-determinada do sistema e a base de dados meteorológica usada para a predição de energia elétrica.

Na seção 4, apresentam-se os resultados obtidos a partir da metodologia proposta; e na seção 5 as conclusões e discussões a partir da análise dos resultados, avaliando-se o desempenho do algoritmo de predição e o de otimização.

2 EMBASAMENTO TEÓRICO

Nesta seção será realizada uma revisão bibliográfica da literatura específica sobre os assuntos correlatos à metodologia proposta nesse projeto de graduação.

2.1 Microrredes

O conceito de microrrede foi introduzido na literatura técnica como solução para a implementação das características das redes inteligentes (SG, do inglês *smart grids),* sem a necessidade de redesenhar e reengenhar todo o sistema de distribuição. Define-se uma microrrede como um sistema elétrico composto por cargas e pequenas unidades de geração distribuída (GD), geograficamente próximas, conectadas a um barramento de baixa tensão (LASSETER, 2002).

As microrredes, usualmente, incluem em sua matriz energética o uso de fontes de energia renováveis, como eólica, solar, célula a combustível, e microcentrais hidrelétricas (SILVA, 2001; KATIRAEI et al., 2008). Este sistema possui como fundamento a capacidade de se isolar da rede elétrica de distribuição, em modo ilhado, ou operar conectado por meio de um ponto de acoplamento comum. As características técnicas de uma microrrede ilhada a tornam adequada para ser instalada em regiões remotas, afastadas da rede de energia, ou em áreas em que a conexão à rede principal não seja vantajosa (QUOC et al., 2016). Por possuir fontes intermitentes, faz parte da sua composição sistemas de armazenamento de energia (BARRIOS, 2015), assim como conversores/inversores de potência e elementos de controle de potência e carga, representados na Figura 1.

2.2 Turbina Eólica

2.2.1 Velocidade do Vento

O vento é originário do aquecimento desigual de áreas da superfície terrestre que ocasionam o deslocamento de massas de ar por suas diferentes densidades. A velocidade do vento, V, varia com a altura, a rugosidade do solo e a localização geográfica, e pode ser estimada a partir de uma velocidade de referência com altura conhecida, V_o, matematicamente expressa na equação

(1). O Quadro 1 especifica o fator de rugosidade para cada classificação do terreno (LOPEZ, 2002). Nesse trabalho os dados de velocidade do vento foram coletados da estação meteorológica localizada no *Campus* de São Mateus da UFES.

$$V = V_1 \, (H/H_1)^n \tag{1}$$

Onde:

V velocidade do vento (m/s);

V_1 velocidade do vento na altura conhecida (m/s);

H altura do eixo horizontal da turbina (m);

H_1 altura conhecida (m);

n fator de rugosidade do terreno.

Quadro 1 – Fator de rugosidade em função do tipo de terreno

Descrição do terreno	**Fator de rugosidade (*n*)**
Sem vegetação	0,1
Gramado	0,12
Cultivado	0,19
Poucas árvores	0,23
Muitas árvores ou poucas edificações	0,26
Florestas	0,28
Zonas urbanas sem edifícios altos	0,32

Fonte: Lopez (2002).

2.2.2 Controle de *Stall* e Controle de Passo

O controle da potência fornecida pelos aerogeradores é feito pelos controles *stall* e de passo. No controle *stall*, as pás do rotor possuem um ângulo de passo fixo e não podem girar em torno de seu eixo longitudinal. O ângulo de passo é determinado para que, em velocidades superiores à nominal, haja um descolamento do fluxo de ar da superfície da pá, reduzindo a força de sustentação e aumentando a força de arrasto, o que ocasiona a diminuição da potência de saída do rotor do aerogerador para não exceder a potência nominal do aerogerador, como ilustrado no Gráfico 3.

Gráfico 3 – Curva de potência: controle *stall*

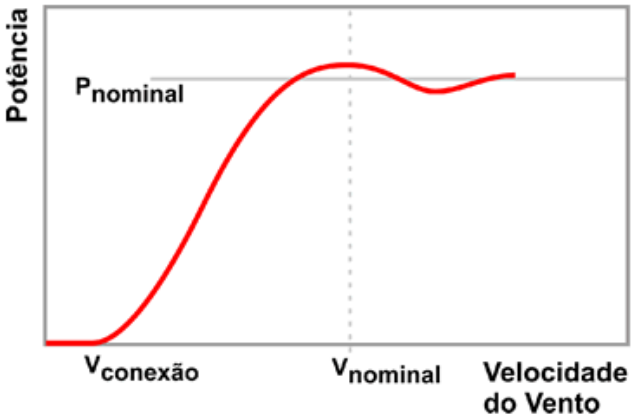

Fonte: Centro de Referência para as Energias Solar e Eólica Sérgio de Salvo Brito (2008).

O controle de passo, por sua vez, altera o ângulo de passo da pá para extrair a potência nominal do aerogerador, também sempre que a potência de saída do rotor ultrapassar o valor nominal. No entanto, apresenta controle de potência ativa para vários valores de vento e alcança a potência nominal mesmo sob condições de baixa massa específica do ar (CRESESB, 2008).

No Gráfico 4 é apresentada a curva de potência para turbinas com controle por ângulo de passo. Neste tipo de controle, o escoamento do vento em torno do perfil da pá é bastante aderente para todas as condições de vento.

Gráfico 4 – Curva de potência: controle por passo

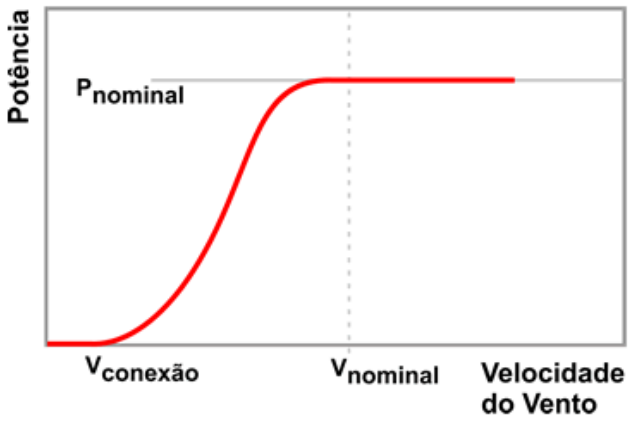

Fonte: Centro de Referência para as Energias Solar e Eólica Sérgio de Salvo Brito (2008).

2.2.3 Modelagem da Turbina Eólica

A potência extraída do vento é proporcional ao cubo da velocidade e é expressa na equação (2) (SLOOTWEG, 2003). Entretanto, nem toda potência disponível em uma massa de ar que flui através da área de varredura das pás *A*, perpendicular ao fluxo do vento, pode ser convertida em potência elétrica. O coeficiente de potência C_p mede esta eficiência sendo definido como a razão entre a potência extraída pela turbina, P_e, e a potência do vento; e está relacionado com o tipo de lâmina, o ângulo de ataque e a relação entre velocidade da ponta da pá e a do vento (GORBAN; GORLOV; SILANTYEV, 2001). O valor teórico máximo de C_p é conhecido como limite de Betz, e é 0,593 (CARRILLO et al., 2013).

$$P_e = \frac{1}{2}\rho A V^3 C_p \tag{2}$$

Onde:

P_e potência extraída pela turbina (W);

V velocidade do vento (m/s);

A área de varredura das pás da turbina (m²);

ρ densidade do ar (kg/m³);

C_p coeficiente de potência.

A equação (2) é complexa para obter a potência gerada pelo aerogerador pois as variáveis dependem das condições de operação da máquina, assim, usualmente, utilizam-se modelos mais genéricos que dependem apenas da velocidade do vento (FIORORRI, 2015). Neste sentido, para descrever a curva não linear de potência, a literatura descreve várias formas de modelagem, sendo o método dos mínimos quadrados o mais empregado para gerar a curva de potência polinomial (CARRILLO et al., 2013) e é descrita na equação (3) (FIOROTTI, 2015).

$$P_e = \begin{cases} 0, & 0 \le V \le V_i \\ \sum_{i=1}^{Np} a_i \text{ x } V^i, & V_i \le V \le V_o \\ 0, & V \ge V_o \end{cases} \tag{3}$$

Onde:

Np grau do polinômio utilizado para a curva de potência;

V velocidade do vento (m/s);

V_i velocidade do vento de partida de operação da turbina eólica (m/s);

V_o velocidade do vento máxima de operação da turbina eólica (m/s);

a_i coeficiente do polinômio.

2.3 Painel Fotovoltaico

O sol é a principal fonte de energia na terra, considerada pelos humanos inesgotável e gratuita. A conversão de energia solar em energia elétrica é obtida por painéis fotovoltaicos (PV, do inglês *photovoltaic panel*) que produzem energia de acordo com a radiação solar incidente.
O efeito fotoelétrico, conceito físico que sustenta esta tecnologia, foi observado pela primeira vez por Alexandre Edmond Becquerel, em 1839 (PINHO; GALDINO, 2014), e satisfatoriamente explicado em 1905, por Albert Einstein, que recebeu o prêmio Nobel de Física de 1921 pelo feito.

A potência máxima que é alcançada por meio da utilização de uma única célula fotovoltaica não excede, em regra geral, a potência de 3 W, o que é insuficiente para a maioria das aplicações reais. Assim, as células fotovoltaicas são normalmente agrupadas (com ligação tipo série) de forma a formar módulos fotovoltaicos (CARNEIRO, 2010). Os arranjos desses módulos formam os painéis, representados na Figura 2.

Figura 2 – Processo hierarquizado de agrupamento

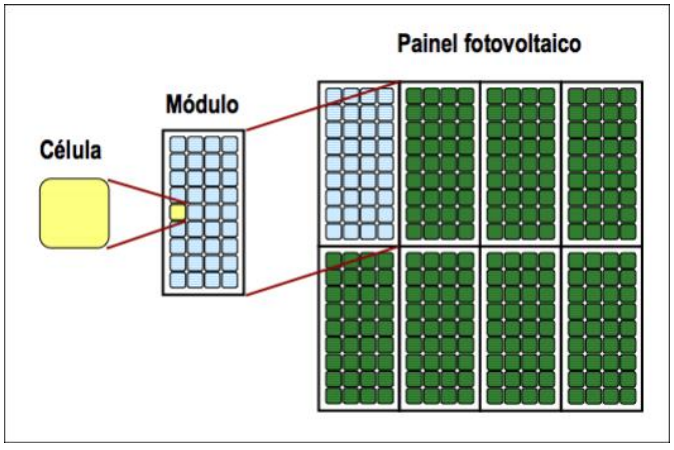

Fonte: Carneiro (2010).

2.3.1 Ponto de Máxima Potência

Os módulos fotovoltaicos são caracterizados pelas curvas corrente por tensão (*I* x *V*) e potência por tensão (*P* x *V*), apresentadas no Gráfico 5. Estas curvas são obtidas nas condições padrão definidas para radiação de 1000 W/m^2 (radiação recebida na superfície da Terra em dia claro, ao meio dia) e temperatura de 25ºC na célula. A partir destas curvas obtém-se o ponto de potência máxima no qual se deseja operar.

O agrupamento de módulos fotovoltaicos do mesmo tipo pode ser efetuado por meio do estabelecimento de ligações em série, paralelo ou mista, obtendo-se assim diferentes valores de tensão ou corrente. A associação em série de módulos fotovoltaicos permite obter tensões mais elevadas, mantendo a corrente estipulada do módulo. Já a ligação em paralelo entre módulos é efetuada quando se pretende obter correntes mais elevadas e manter o nível de tensão estipulada do módulo (CARNEIRO, 2010).

Gráfico 5 – Curvas I x V e P x V do módulo fotovoltaico: parâmetros de potência máxima

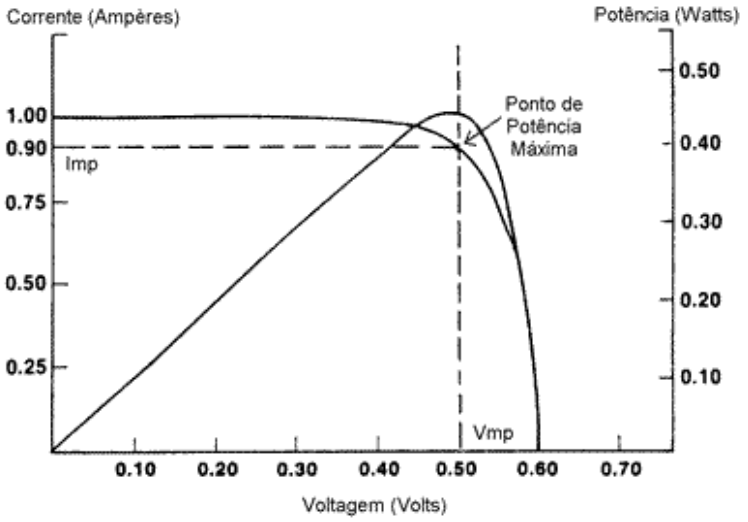

Fonte: Centro de Referência para as Energias Solar e Eólica Sérgio de Salvo Brito (2008).

Os arranjos fotovoltaicos são suscetíveis à redução de desempenho e segurança, devido ao sombreamento parcial causado por barreiras de luz, como árvores, folhas, linhas de energia, detritos, poeira, neve e excrementos de pássaros. Quando se trata de módulos conectados em série, a maior corrente do arranjo é igual à corrente do módulo com o menor desempenho e isso

reduz significativamente a eficiência do conjunto (SOUZA, 2019), além da célula poder se polarizar inversamente e superaquecer.

Em adição, os diodos de *bypass* também são utilizados como dispositivos de proteção. Quando existe sombreamento na célula, o diodo encontra-se diretamente polarizado, permitindo que por ele circule corrente elétrica (MARQUES, 2017).

2.3.2 Modelagem do Painel Fotovoltaico

A potência incidente em um módulo fotovoltaico, matematicamente expressa na equação (4), é igual ao produto entre a irradiação solar e a área sobre a qual a irradiação incide. Entretanto, como apenas uma fração dessa potência incidente é convertida em energia elétrica, a potência gerada pelo módulo, $P_{v,}$ é a potência incidente multiplicada pelo rendimento (ZHAO et al., 2014).

$$P_f = \eta \, r \, S \tag{4}$$

Onde:

P_f potência gerada pelo módulo fotovoltaico (W);

η rendimento do painel fotovoltaico;

r irradiação solar (W/m²);

S área do painel fotovoltaico (m²).

A radiação solar e a temperatura influenciam o comportamento dos módulos fotovoltaicos. A corrente gerada nos módulos aumenta linearmente com o crescimento da irradiação solar e o aumento da temperatura na célula diminui a tensão gerada pelo modulo, como se observa no Gráfico 6.

Apesar da equação (4) apresentar a vantagem de uma modelagem simples, ela não leva em consideração a influência da temperatura e irradiação solar na eficiência do painel em seus variados pontos de operação. Assim, foi adotado o modelo matemático de painel fotovoltaico, expresso pelas equações (5) a (9) e proposto por Abdelaziz e outros (2015), porque considera a eficiência do painel para diferentes pontos de operação.

Gráfico 6 – Influência da radiação solar e temperatura na curva I x V do módulo fotovoltaico

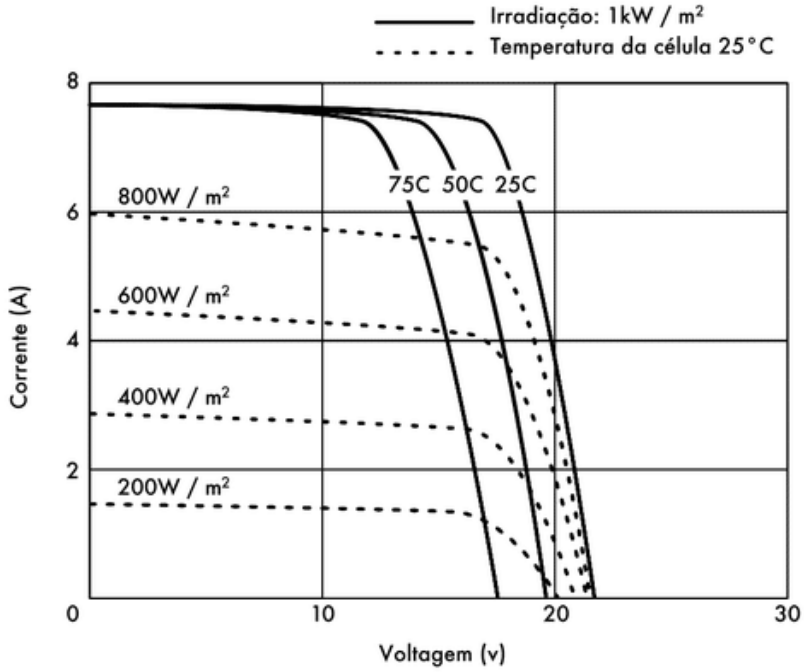

Fonte: Centro de Referência para as Energias Solar e Eólica Sérgio de Salvo Brito (2008).

$$P_f = Npv \text{ x } FF \text{ x } V \text{ x } I \quad (5)$$

Sendo que:

$$T_c = T_a + r\,[(N_{ot} - 20) / 0{,}8] \quad (6)$$

$$I = r\,[I_{sc} + K_i\,(T_c - 25)] \quad (7)$$

$$Vpv = V_{oc} - K_v \text{ x } T_c \quad (8)$$

$$FF = (V_{mppt} \text{ x } I_{mppt}) / (V_{oc} \text{ x } I_{sc}) \quad (9)$$

Onde:

P_f potência fotovoltaica (W);

Npv número de painéis;

T_c temperatura do painel fotovoltaico (C);

T_a temperatura do ambiente (C);

N_{ot} temperatura nominal de operação da célula (C);

I corrente na célula (A);

r irradiação solar (W/m²);

I_{sc} corrente de curto circuito da célula (A);
K_i coeficiente de corrente/temperatura (A/°C);
Vpv tensão no módulo fotovoltaico (V);
V_{oc} tensão de circuito aberto do módulo (V);
K_v coeficiente de tensão/temperatura (V/°C);
FF fator de forma;
V_{mppt} tensão no ponto de máxima potência (V);
I_{mppt} corrente no ponto de máxima potência (A).

2.4 Armazenamento de Energia Elétrica

Em sistemas com geração distribuída (GD), o uso de fontes renováveis intermitente causa oscilações na disponibilidade de energia, explicitando a necessidade de um sistema de armazenamento de energia para aumentar a eficiência e confiabilidade da microrrede (NASCIMENTO, 2014).

O estacionamento inteligente proposto possuirá um banco de baterias e a operação e o controle do mesmo é essencial para o gerenciamento ótimo da microrrede, sendo o estado de carga da bateria fundamental no processo. Além disso, a profundidade da descarga durante cada ciclo de uso da bateria tem impacto em sua vida útil (WANG; HONG, 2015). Assim, para modelar as baterias, os limites da carga serão definidos pela equação (10) e o banco de baterias utilizado no SP está descrito no Quadro 2.

$$SOC_{min} \leq SOC \leq SOC_{max} \quad (10)$$

Onde:
SOC_{min} estado de carga mínimo da bateria (kWh);
SOC estado de carga da bateria (kWh);
SOC_{max} estado de carga máximo da bateria (kWh).

Quadro 2 – Dados do banco de baterias do SP

Parâmetro	Banco de Baterias
Quantidade de baterias	7
Energia Total	98 kWh
Energia Usável	94,5 kWh
Eficiência	90%

Fonte: Tesla (2019).
Nota: Adaptado pelo autor.

2.5 Veículos Elétricos

Os carros elétricos são os usuários do estacionamento inteligente e o carregamento precisa ser também modelado. O carregamento e o descarregamento dos carros elétricos são limitados conforme a equação (11) (RICHARDSON; FLYNN; KEANE, 2012).

$$0 \leq Pev_i \leq Pev_i^{max} \tag{11}$$

Onde:

i = 1, 2, ..., N_{ev}.

N_{ev} número de carregadores;

Pev carregamento do carro elétrico (kW);

Pev^{max} carregamento máximo do carro elétrico (kW).

Há também restrições à variação da taxa de carregamento, que não pode sofrer uma variação superior ao valor expresso por Δ, em equação (12) (OSORIO et al., 2013), e o limite de Δ é de 35 pontos percentuais em relação ao estado de carga da bateria, como descrito em Coelho e outros (2016). As características do modelo de veículo elétrico utilizado no SP estão descritas no Quadro 3.

$$Pev_i^{t-1} - \Delta \leq Pev_i^t \leq Pev_i^{t-1} + \Delta \tag{12}$$

Onde:

i = 1, 2, ..., N_{ev}.

Pev taxa de carregamento do carro elétrico (kW);

t intervalo de tempo;

Δ variação na taxa de carregamento do carro elétrico (kW).

Quadro 3 – Características técnicas dos veículos elétricos

Características dos Veículos Elétricos (PEV)	**Valor Numérico**
Quantidade de PEV	10
Quantidade de carregadores do SP	4
Energia total de cada PEV	24 kWh
Energia usável de cada PEV	18 kWh
Taxa máxima de carga/descarga de cada PEV	8,5 kWh

Fonte: Ferreira (2018).
Nota: Adaptado pelo autor.

2.6 Redes Neurais Recorrentes

A inteligência artificial reúne métodos computacionais inspirados na capacidade humana de aprendizagem, que podem avaliar e classificar novas informações baseados em relações criadas a partir de dados prévios e, neste aspecto, se destacam as redes neurais (HAYKIN, 2001). Estas possuem arquitetura inspirada na estrutura neural de organismos inteligentes que adquirem conhecimento por meio da experiência – criando relações, errando e fazendo descobertas.

As redes neurais tradicionais não são capazes de utilizarem informações aprendidas em etapas anteriores para modelar informações da etapa atual e, neste sentido, as redes neurais recorrentes (RNN, do inglês *recurrent neural network*) apresentam-se com a característica de conexões cíclicas onde as conclusões sobre um novo dado de entrada é também fundamentado em aprendizagens prévias.

Há, no entanto, variações de RNN, como a unidade de memória de longo-curto prazo (LSTM, do inglês *long short-term memory*), que se destaca por ser capaz de relacionar informações tanto no curto período quanto padrões característicos em longas sequencias de dados, sendo assim amplamente utilizadas para predição de potência que utilizam extensas bases de dados meteorológicos, como em Wang, Qi e Liu (2019), Nasser e Mahmoud (2017) e Gensler, Hense e Sick (2016).

Diferentemente das redes neurais tradicionais, que possuem neurônios como unidade básica, a LSTM possui bloco de memória conectados através das sucessivas camadas. O bloco de memória, representado na Figura 3 e modelado pelas equações (13) a (17), é formado pelo portão de entrada, que baseado no conhecimento prévio avalia qual informação de entrada será usada

para atualizar o estado da memória; o portão de saída, que a partir do estado de memória e dado de entrada define a saída; e o portão de esquecimento, que descarta as informações não agregadoras ao bloco de memória (NASSER; MAHMOUD, 2017).

Figura 3 – Bloco de memória LSTM

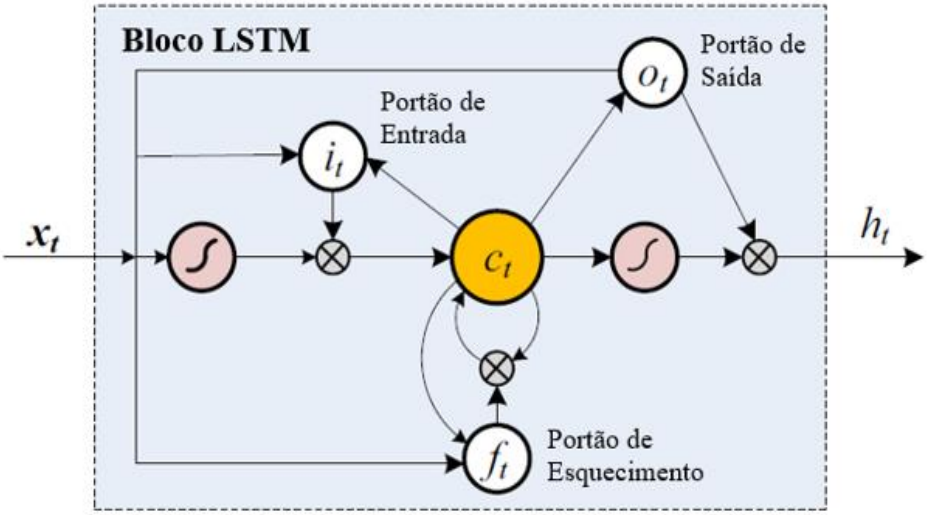

Fonte: Nasser e Mahmoud (2017).
Nota: Adaptado pelo autor.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (13)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (14)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (15)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (16)$$

$$h_t = o_t \tanh(c_t) \quad (17)$$

Onde:

t tempo;

c estado da unidade de memória;

i portão de entrada;

f portão de esquecimento;

o portão de saída;

x dado da camada X;

h dado da camada H;

b constante *bias*;

W peso do estado da memória ;

σ função de ativação.

Em adição, a raiz quadrática média do erro (RMSE, do inglês *root mean square error*), como na equação (18), é uma métrica importante para validação do algoritmo de rede neural de predição numérica. Observando o RMSE entre diferentes conjuntos de dados, pode-se avaliar a acurácia e generalização da rede (NEILL; HASHEMI, 2018).

$$\text{RMSE} = \sqrt{\frac{1}{n_a} \sum_{i=1}^{n_a} \left(x_p - x_o\right)^2} \tag{18}$$

Onde:

x_i valor da variável predita;

x_o valor da variável observada;

n_a número de observações para análise.

2.7 Metaheurísticas de Busca Gravitacional

Metaheurísticas são boas ferramentas para solucionar problemas de complexa modelagem, por apresentarem algoritmo genéricos que podem ser adaptados para a otimização de sistemas (SABRI; PUTEH; MOHAMAD, 2013). Neste trabalho, foi utilizado o algoritmo de busca gravitacional (GSA, do inglês *gravitational search algorithm)* para avaliar o desempenho na solução de problemas de despacho de energia.

O GSA é um algoritmo baseado na lei da gravidade e interação entre massas, em que a partir de uma população inicial, avalia-se os melhores e piores agentes, alterando suas características para que a população ao longo das interações convirja para a maximização ou minimização da função de avaliação (*fit*, do inglês *fitness*) (RASHEDI; POUR; SARYAZDI, 2009).

A posição de cada agente, ou massa, que forma uma população, representa uma possível solução do problema. O agente possui como característica posição espacial, massa inercial, massa gravitacional ativa e passiva; e a cada interação esses parâmetros são reajustados para

que a longo prazo os agentes sejam atraídos pelo agente de maior massa, como na Figura 4. Este com maior massa, representa no espaço de busca, uma solução otimizada.

Figura 4 – Espaço de busca gravitacional

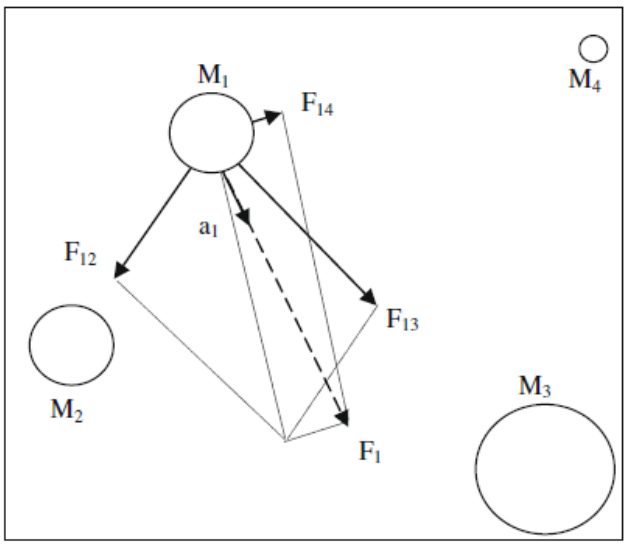

Fonte: Rashedi, Pour e Saryazdi (2009).

A modelagem do algoritmo é expressa pelas equações (19) a (31) e o fluxograma da Figura 5 apresenta a cronologia de funcionamento do GSA (RASHEDI; POUR; SARYAZDI, 2009), sendo a função de avaliação expressa posteriormente e o critério de parada definido pelo número de interações do algoritmo.

$$X_i = (x_i^1, \dots, x_i^d, \dots x_i^n) \tag{19}$$

$$G(t) = G(G_0, \mathrm{t}) \tag{20}$$

$$best(t) = \max_{j \in \{1,\dots,N\}} fit_j(t) \tag{21}$$

$$worst(t) = \min_{j \in \{1,\dots,N\}} fit_j(t) \tag{22}$$

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \tag{23}$$

$$m_i(t) = \frac{m_i(t)}{\sum_{j=1}^{N} m_j(t)} \tag{24}$$

$$M_{ai} = M_{pi} = M_{ii} = M_i \tag{25}$$

$$R_{ij}(t) = \left\| x_i(t), m_j(t) \right\|_2 \tag{26}$$

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t) - M_{aj}(t)}{R_{ij}(t) + €} (x_j^d(t) - x_i^d(t)) \tag{27}$$

$$F_i^d(t) = \sum_{j=1,\ j \neq i}^{N} rand_j \, F_{ij}^d(t) \tag{28}$$

$$a_i^d(t) = \frac{F_i^d(t)}{M_{ii}(t)} \tag{29}$$

$$v_i^d(t+1) = rand_i * v_i^d(t) + a_i^d(t) \tag{30}$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \tag{31}$$

Sendo:

$i = j$ =1,2,...,N.

Onde:

i	massa i;
j	massa j;
N	número de agentes;
t	tempo t;
x	posição do agente;
d	dimensão do agente;
a	aceleração;
F	força gravitacional;
M_a	massa gravitacional ativa;
M_p	massa gravitacional passiva;
M_i	massa gravitacional inercial;
G	constante gravitacional;
R	distância Euclidiana;
€	constante;
v	velocidade do agente;
fit	função objetivo.

Figura 5 – Fluxograma do GSA

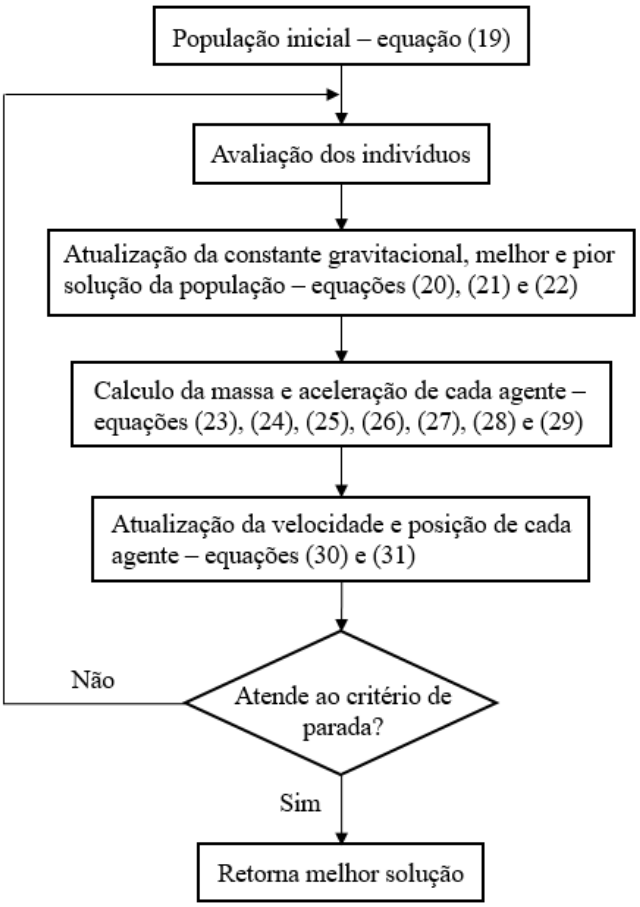

Fonte: Produzido pelo próprio autor.

3 ESTACIONAMETO INTELIGENTE

3.1 Dados Históricos e Organização da Base de Dados

Para a realização da predição de potência utilizando a rede neural LSTM, foram utilizados os dados da estação meteorológica localizada no *Campus* de São Mateus da Universidade Federal do Espírito Santo (UFES). Estes foram coletados de hora em hora, entre os dias 01/01/2014 a 20/04/2016, correspondendo a 20.160 amostragens de entrada. Cada padrão contém as seguintes variáveis:

- Data;
- Hora (UTC);
- Temperatura média (ºC);
- Umidade relativa média (%);
- Pressão média (hPa);
- Velocidade do vento (m/s);
- Direção do vento;
- Rajada do vento (m/s);
- Irradiância (kW/m²).

Implementada a modelagem de fontes de energia, a LSTM retorna a previsão de potência da microrrede que, junto com a demanda, são entradas para o otimizador.

3.2 Predição de Potência Gerada

A utilização de fontes energéticas carbono-zero é fundamental para garantir que as fontes primárias de energia elétrica, posteriormente usada para abastecer os veículos, não sejam poluentes. Foram utilizados no SP catorze painéis fotovoltaicos e uma turbina eólica.

3.2.1 Caracterização do Aerogerador

Visando ao dimensionamento e ao custo realista do sistema, é utilizada uma turbina eólica *Enersud Verne 555* com potência nominal de 6 kW, que possui controle de *stall* e está caracterizada no Quadro 4.

Quadro 4 – Especificações técnicas adaptado do gerador eólico Enersud Verne 555

Parâmetro	Verne 555
Potência nominal	6000 W
Velocidade *Cut-out*	16 m/s
Velocidade *Cut-in*	3 m/s

Fonte: Enersud (2017).
Nota: Adaptado pelo autor.

A potência do aerogerador foi modelada pela equação (3) e, para determinar os coeficientes do polinômio representados no Gráfico 7, utilizaram-se os dados obtidos no manual da turbina eólica e a ferramenta *polyfit* do s*oftware* MatLab. Destaca-se que foi desenvolvido um polinômio de sexto grau, com coeficientes descritos no Quadro 5, pelo resultado satisfatório em comparação com a curva de potência apresentada no manual e menor esforço computacional.

Quadro 5 – Coeficientes do polinômio da curva de potência

Coeficientes	
a_1	0,0007
a_2	-0,0333
a_3	0,5709
a_4	-4,4052
a_5	15,7589
a_6	-20,5212

Fonte: Produzido pelo próprio autor.

Gráfico 7 – Curva de potência eólica real e modelada

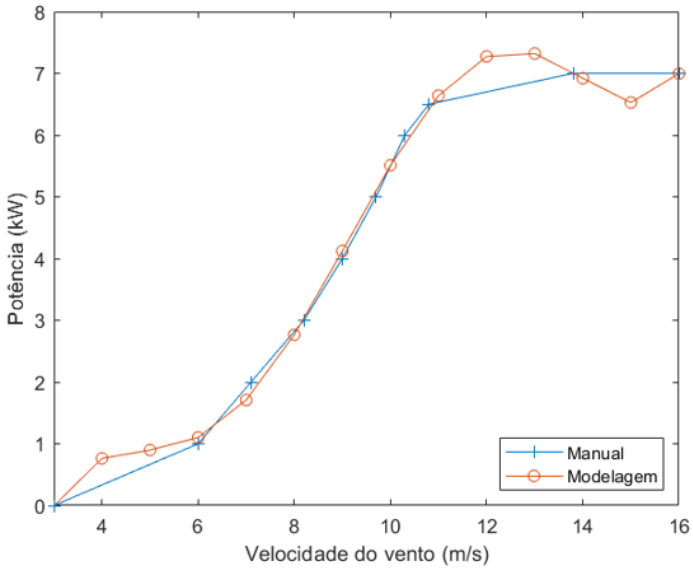

Fonte: Produzido pelo próprio autor.

3.2.2 Caracterização do Painel Fotovoltaico

O painel fotovoltaico usado no SP é o *Canadian Solar* CS6P-260, descrito no Quadro 6, sendo adotado o modelo matemático de painel fotovoltaico expresso pelas equações (5) a (9).

Quadro 6 – Especificações técnicas do painel fotovoltaico *Canadian Solar* CS6P-260

Parâmetro	**CS6P-260**
Potência nominal	260 W
Tensão de circuito aberto do módulo	37,5 V
Corrente de curto circuito da célula	9,21 A
Tensão no ponto de máxima potência	30,4 V
Corrente no ponto de máxima potência	8,56 A
Coeficiente de tensão/temperatura	0,31 V/°C
Coeficiente de corrente/temperatura	0,053 A/°C
Temperatura nominal de operação da célula	45 °C

Fonte: *Canadian Solar* (2016).
Nota: Adaptado pelo autor.

3.2.3 Caracterização da Rede Neural

Utilizando os modelos de fontes energéticas e a base de dados, obteve-se a potência real gerada, para o treinamento da LSTM. Para cada fonte de energia foi treinado uma rede neural, devido as suas diferenças de modelagem e natureza dos dados, sendo utilizadas para treinamento e teste, apenas as variáveis englobadas no modelo matemático de cada, no tempo (t), assim como a respectiva potência deslocada em (t+24).

O conjunto de dados de treino foi criado com 80% da base de dados e o conjunto de teste com os 20% restantes. Este, por sua vez, utilizado para evitar o problema de sobre ajuste (*overfitting*, do inglês), ou seja, avaliar se a rede está aprendendo a cada época para ser capaz de generalizar, e não decorando padrões do treino. Também neste sentido, a cada camada foram excluídos 10% das conexões para que a rede não se especialize nos dados de entrada.

A topologia da rede foi configurada baseada na experimentação e literaturas citadas, com três camadas LSTM, dedicadas a abstração das características dos dados, e quatro camadas densa para regressão (HAYKIN, 2001), com taxa de aprendizado de $\lambda = 16$, para o treinamento por

64 épocas. As funções de ativação utilizadas foram a ReLU, a Sigmoid e a Linear (HAYKIN, 2001) e a arquitetura da rede está expressa no Quadro 7.

Quadro 7 – Arquitetura da rede neural

N° Camada	Tipo da Camada	Núcleo (N° Dimensões)	Função de Ativação
1	Entrada	Nenhum	Nenhuma
2	LSTM	1024	ReLU
3	LSTM	256	ReLU
4	LSTM	128	ReLU
5	Dense	1024	ReLU
6	Dense	256	ReLU
7	Dense	128	Sigmoid
8	Dense (Saída)	24	Linear

Fonte: Produzido pelo próprio autor.

3.3 Definição da Demanda

A demanda previamente definida do SP, caracterizada no Quadro 8, contém a identificação dos dez PEV, e também indica a prioridade, o horário de chegada e saída, assim como o SOC na chegada e o previsto para a saída.

Quadro 8 – Demanda do SP

PEV	Chegada (h)	Saída (h)	soc^c	soc^s
1	20	21	21%	56%
2	6	10	14%	80%
3	3	20	40%	67%
4	14	24	8%	41%
5	8	9	47%	56%
6	17	24	8%	41%
7	15	24	79%	98%
8	7	24	62%	98%
9	8	24	62%	98%
10	2	5	79%	95%

Fonte: Alves e outros (2019).
Nota: Adaptado pelo autor.

3.4 Funcionamento do Banco de Baterias

O banco de baterias foi modelado pela equação (10), tendo definido seus limites de carga, e a lógica de funcionamento implementada está descrita na Figura 6.

Figura 6 – Fluxograma da lógica de funcionamento do banco de baterias

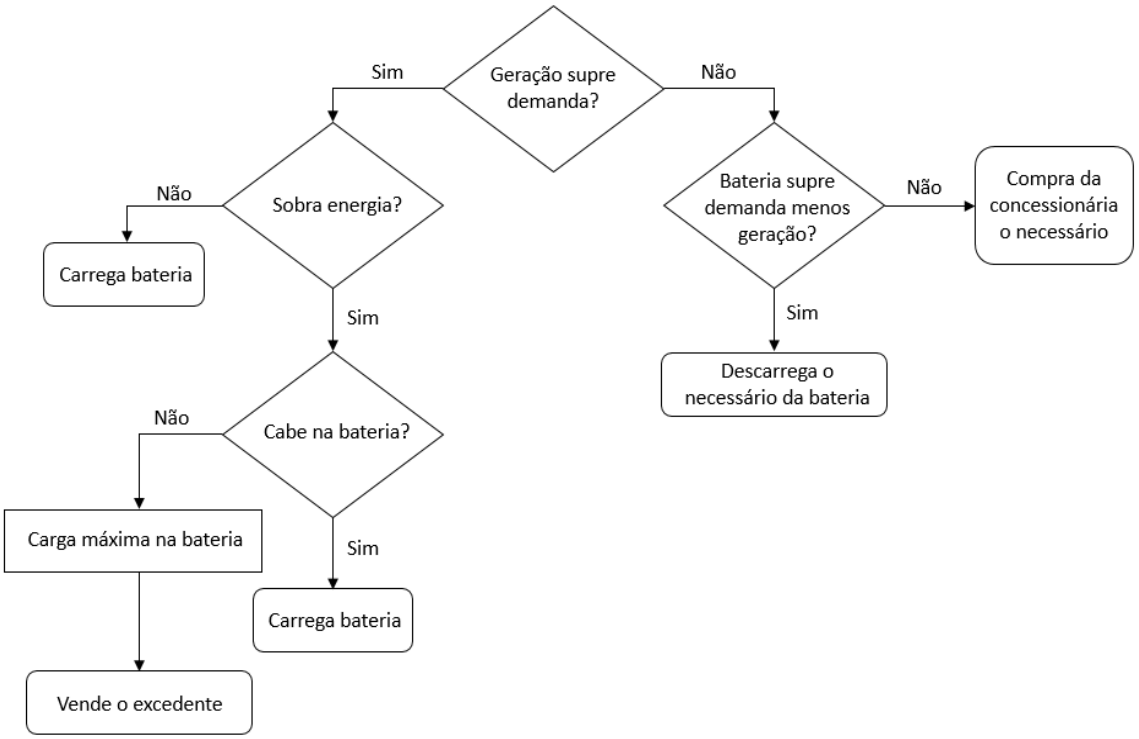

Fonte: Produzido pelo próprio autor.

3.5 Codificação da Solução

A população inicial gerada pelo GSA é uma matriz tridimensional, com 100 indivíduos, representada na Figura 7, com valores inteiros entre ‘0’ e ‘2’ que expressam o estado de operação do PEV. O valor ‘0’ indica que o veículo não está no SP, o ‘1’ para quando está carregando e ‘2’, descarregando. No Quadro 9 é exposto um indivíduo da população, ou seja, uma possível solução.

Figura 7 – População inicial do GSA

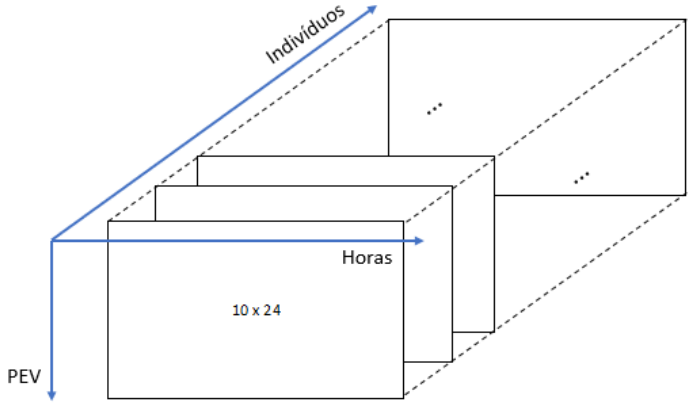

Fonte: Produzido pelo próprio autor.

Quadro 9 – Indivíduo do GSA

	1 h	**2 h**	**3 h**	**...**	**24 h**
PEV 1	1	2	0	**...**	1
PEV 2	2	1	2	**...**	0
PEV 3	0	2	2	**...**	2
...	**...**	**...**	**...**	**...**	**...**
PEV 10	0	2	1	**...**	1

Fonte: Produzido pelo próprio autor.

A função objetivo é aplicada a todos os indivíduos da população a cada interação com o intuito de avaliar as melhores soluções. Usa-se neste trabalho uma função mono-objetivo com penalização caso algum PEV deixe o SP com SOC menor que o demandado, que é descrita nas equações (32), (33) e (34). As constantes utilizadas têm os valores de k_{soc} = 100 e k_e = 1, e a variável D_{soc} representa a diferença entre a energia demandada e a real, quando a possível solução não atender a demanda.

$$Fitness = \left\{ \sum_{i=1}^{24} \left[\left(C_{ec}(i) - C_{ev}(i) \right) * \ k_e(i) \right] \right\} + C_{soc} * k_{soc} * D_{soc} \quad (32)$$

Onde:

C_{ec} custo energia comprada (R$);

C_{ev} custo energia vendida (R$);

k_e peso custo da energia ;

C_{soc} contador de penalização para SOC menor que o demandado;

k_{soc} peso SOC insuficiente;

D_{soc} peso para diferença entre SOC e SOC demandado;

Sendo :

$$C_{ec}(i) = \begin{cases} E_c(i) * R\$_{fora\ ponta} , & 1 \leq i \leq 17\ ou\ 23 \leq i \leq 24 \\ E_c(i) * R\$_{intermediário}, & i = 18\ ou\ i = 22 \\ E_c(i) * R\$_{ponta} , & 19 \leq i \leq 21 \end{cases} \quad (33)$$

$$C_{ev}(i) = \begin{cases} E_v(i) * R\$_{fora\ ponta} , & 1 \leq i \leq 17\ ou\ 23 \leq i \leq 24 \\ E_v(i) * R\$_{intermediário}, & i = 18\ ou\ i = 22 \\ E_v(i) * R\$_{ponta} , & 19 \leq i \leq 21 \end{cases} \quad (34)$$

Onde :

E_c energia comprada (kWh);

E_v energia vendida (kWh);

$R\$_{fponta}$ valor da energia em horário fora ponta (R$/kWh);

$R\$_i$ valor da energia em horário intermediário (R$/kWh);

$R\$_{ponta}$ valor da energia em horário ponta (R$/kWh).

A modalidade tarifária horária Branca de energia, regulamentada pela Agência Nacional de Energia Elétrica (ANEEL), na Resolução Homologatória Nº 2.589/2019, foi utilizada no SP para o cálculo do valor da energia, por possuir ao longo do dia três postos horários: fora ponta, intermediário e ponta. O SP foi considerado do subgrupo B3, com Bandeira Tarifária Verde, e tarifa é definida como a soma da tarifa de uso do sistema de distribuição (TUSD) e da tarifa de energia (TE). Não foram levados em consideração neste trabalho os impostos e o valor da energia está descrito no Quadro 10.

Quadro 10 – Valor da energia fornecida pela concessionária

	TUSD + TE (R$/kWh)
$R\$_{fora\ ponta}$	0,49258
$R\$_{intermediário}$	0,74395
$R\$_{ponta}$	1,15244

Fonte: Agência Nacional de Energia Elétrica (2020).
Nota: Adaptado pelo autor.

4 RESULTADOS E DISCUSSÕES

4.1 Métrica de Validação da LSTM

A predição de potência solar e eólica deste trabalho foi obtida a partir do treinamento de duas redes neurais LSTM, devido à distinção entre as variáveis usadas para prever cada uma delas e obtiveram bom desempenho, com assertividade de 94,04% e 92,9%, respectivamente, como mostrado no Gráfico 8 e Gráfico 9.

Os neurônios das redes neurais, ou unidades de memória no caso específico da LSTM, recebem valores de entrada multiplicados por pesos, que representam a força de relação entre eles. Assim, calcula-se a perda de cada neurônio, ou seja, a diferença entre a saída desejada e a atual, para que ao longo do treinamento sejam reajustados os pesos no intuito de minimizar a perda, ou em outras palavras, maximizar a assertividade da rede.

O RMSE descrito na equação (18) é a métrica de validação usada para quantificar a perda da rede, descrito nos Gráfico 8 e Gráfico 9. Observa-se também que os valores gerados a partir dos dados de treino e de teste convergem. Isto é, quando a rede executa dados nunca vistos, obtém-se valores similares de RMSE, por não se especializar no conjunto de treinamento, preservando a desejada característica de generalização.

Gráfico 8 – Perda da rede neural na predição da potência solar

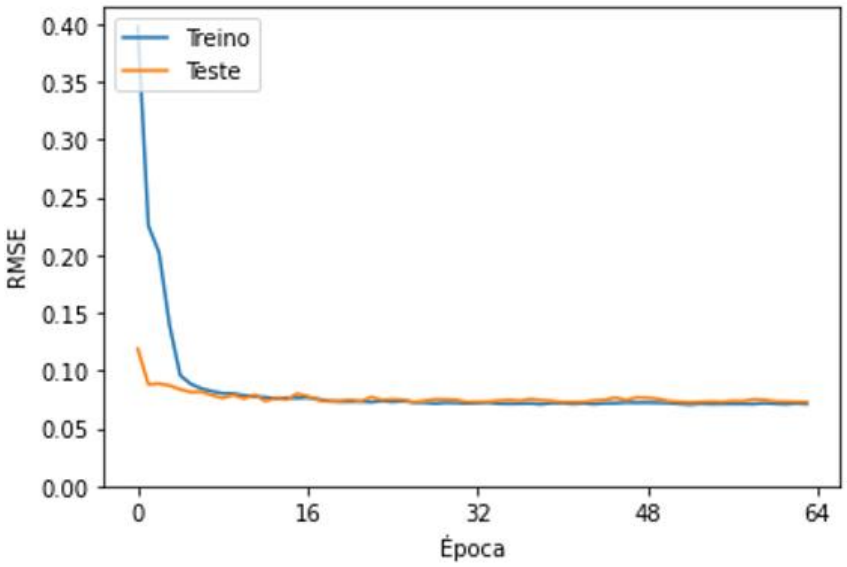

Fonte: Produzido pelo próprio autor.

Gráfico 9 – Perda da rede neural na predição da potência eólica

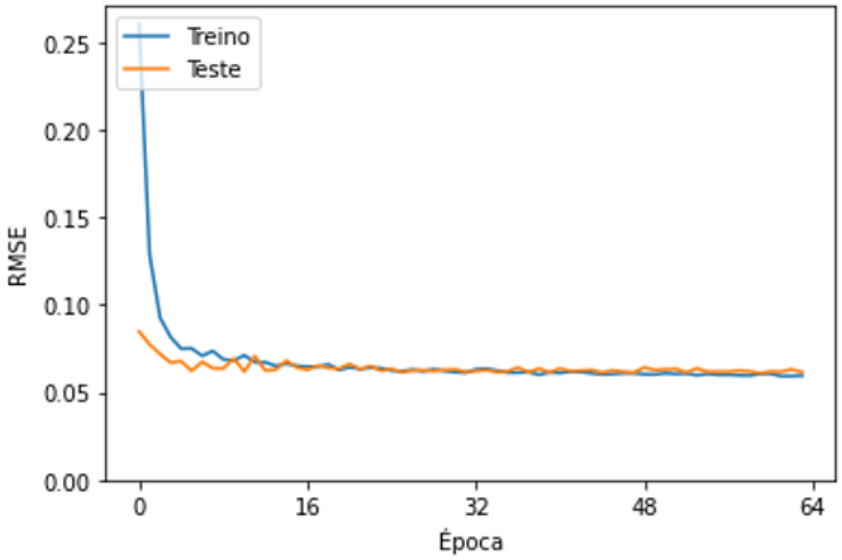

Fonte: Produzido pelo próprio autor.

4.2 Comparação entre Potência Real e Predita

O Gráfico 10 e Gráfico 11 apresentam a comparação entre a potência real e a predita para o período do ciclo do SP. Observa-se que a assertividade da LSTM é maior na predição da potência solar devido o conjunto de dados possuir um padrão melhor definido, enquanto a potência eólica apresenta maior variação na natureza das variáveis do modelo.

Gráfico 10 – Comparação entre potência solar real e predita

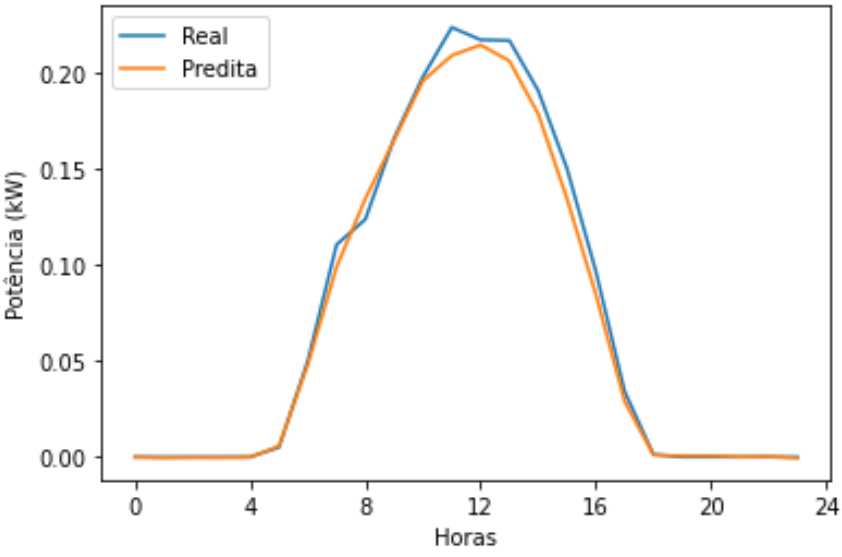

Fonte: Produzido pelo próprio autor.

Gráfico 11 – Comparação entre potência eólica real e predita

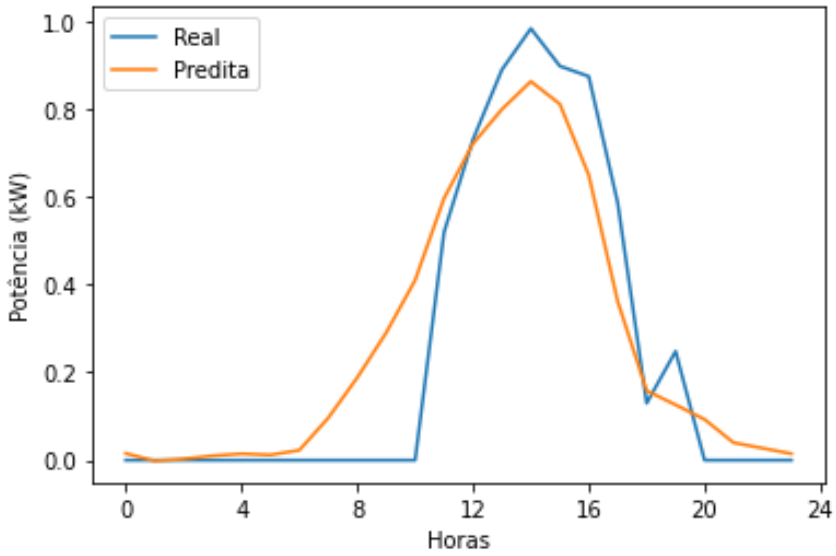

Fonte: Produzido pelo próprio autor.

4.3 Análise do Otimizador

O GSA, metaheurística utilizada para otimização do SP, possui a particularidade de propor o conceito de busca espacial, para a cada nova geração obter um conjunto mais bem avaliado pela função objetivo tendo, assim, a distinção numérica entre os indivíduos, uma característica relevante para o bom funcionamento do algoritmo.

Logo, pela natureza da codificação do problema de despacho de energia deste trabalho, foi feita a transformação dos agentes para valores inteiros – ‘0’, ‘1’ e ‘2’ – e, por isso, observa-se no Gráfico 12 que a função avaliação satura sem zerar o custo da energia do sistema. Entretanto, devido aos diferentes pesos atribuídos às variáveis da função objetivo, foi atingido o objetivo principal de atender todas as características da demanda.

O otimizador do estacionamento inteligente foi projetado para obter o melhor planejamento de carregamento dos veículos elétricos do sistema e, no Gráfico 13, observa-se que o objetivo foi atingido pois, ao final da otimização, o contador de penalidade para veículos que deixa o SP com o estado de carga da bateria inferior ao determinado na demanda é nulo.

Gráfico 12 – Desempenho dos indivíduos ao longo das gerações

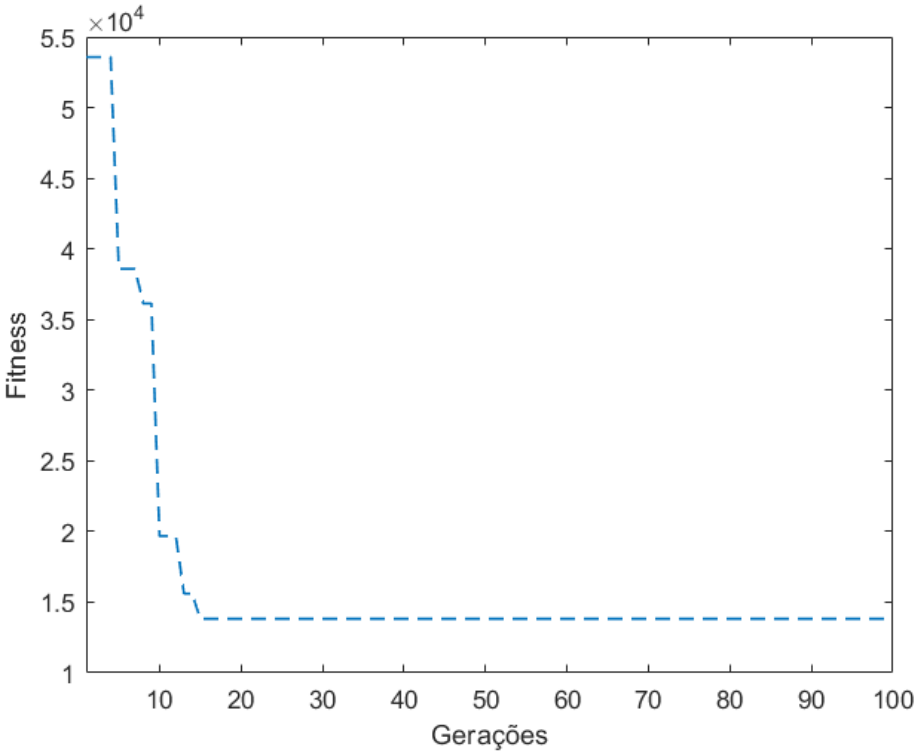

Fonte: Produzido pelo próprio autor.

Gráfico 13 – Penalização por estado de carga final insuficiente dos veículos elétrico ao longo das gerações

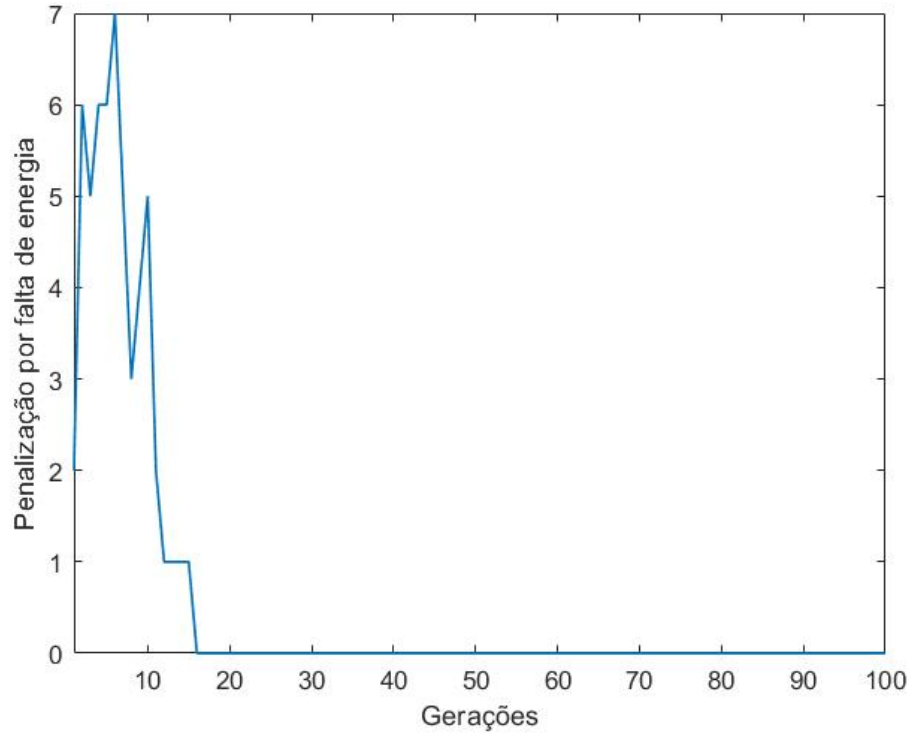

Fonte: Produzido pelo próprio autor.

O Gráfico 14 exibe o histórico de carga do banco de baterias, caracterizando maior fluxo de carga e descarga entre a hora 13 e a hora 22. Já o Gráfico 15, retrata o histórico de carga das baterias dos veículos PEV1, PEV2, PEV3 e PEV4, como ilustração do comportamento de carregamento e descarregamento dos veículos elétricos ao longo das 24 horas.

Os marcadores circulares representam, no eixo horizontal, o horário em que os veículos elétricos deixam o estacionamento e, no eixo vertical, o estado de carga da bateria, como definido pela demanda. O PEV3 e o PEV4 apresentam respectivamente 33% e 62% de SOC a mais do que o demandado, assim, concluindo-se que há condições para uma melhora no desempenho do otimizador. O Gráfico 15 possibilita novamente constatar que o objetivo principal é alcançado por os veículos deixarem o SP com nível de carga maior ou igual ao predeterminado.

Gráfico 14 – Estado de carga do banco de baterias ao longo das 24 horas

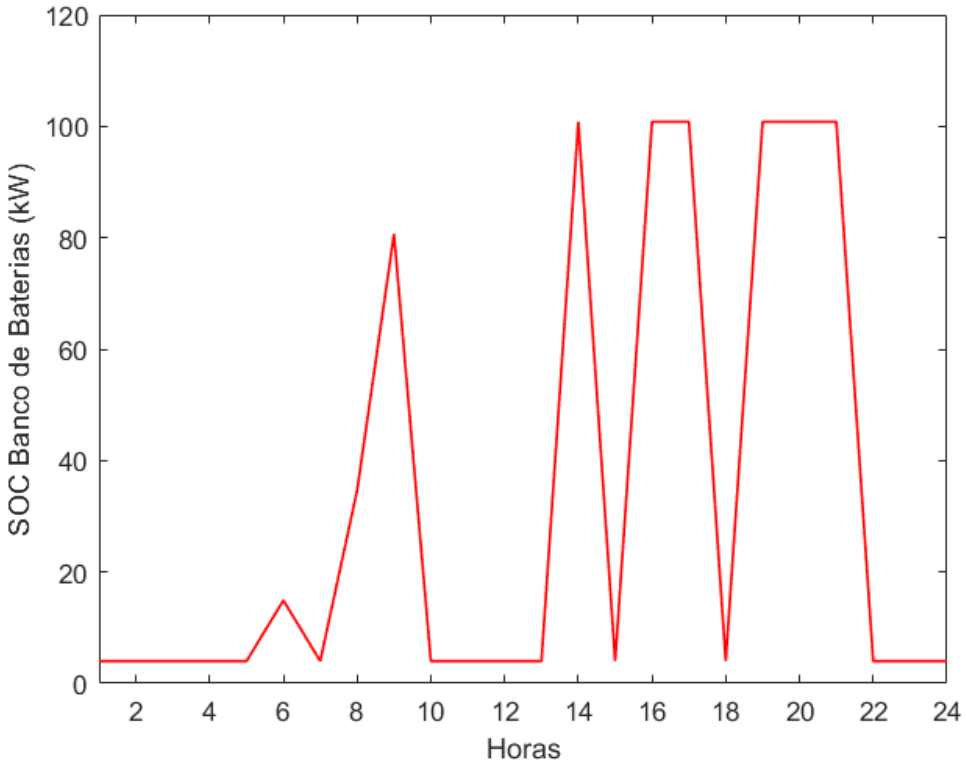

Fonte: Produzido pelo próprio autor.

Gráfico 15 – Estado de carga dos veículos PEV1, PEV2, PEV3 e PEV4 ao longo das 24 horas

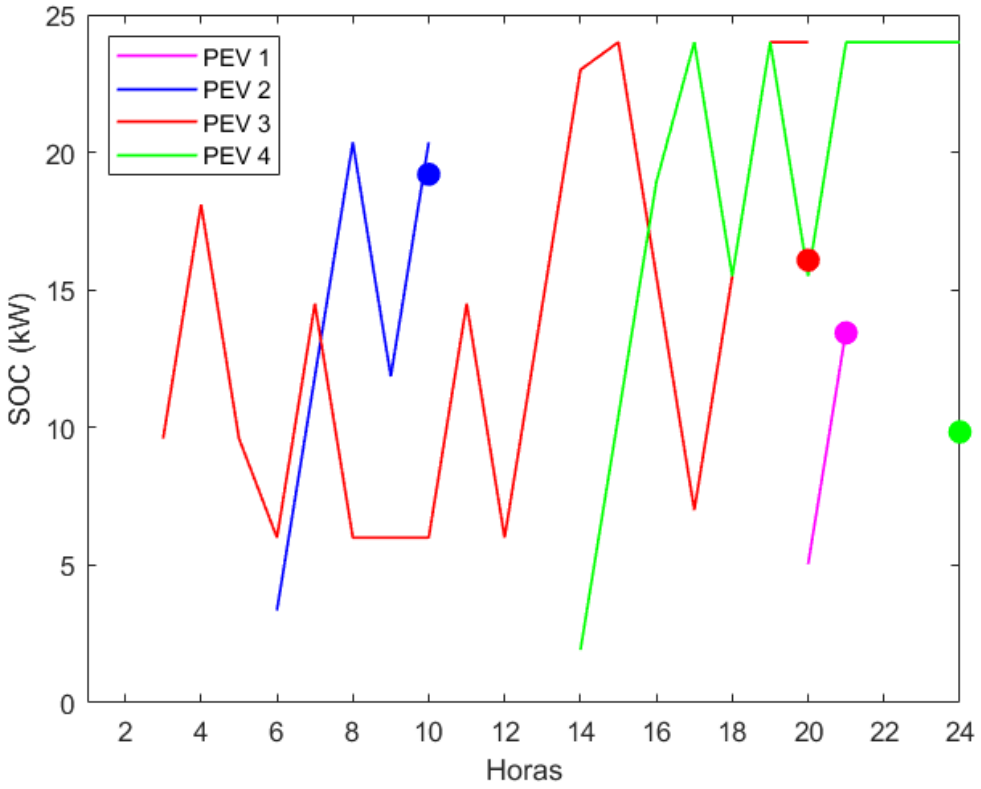

Fonte: Produzido pelo próprio autor.

5 CONCLUSÕES E TRABALHOS FUTUROS

O objetivo geral deste trabalho foi atingido pelo sistema por propor o melhor planejamento energético para os veículos elétricos da microrrede modelada, com 24 horas de antecedência e atendendo à demanda solicitada. Assim, comprova-se a eficácia da utilização de metaheurísticas para problemas matemáticos complexos, como o despacho de energia.

Os objetivos específicos foram alcançados com a modelagem matemática da turbina eólica e de painéis fotovoltaicos, em convergência com o estado da arte, que obtiveram resultados fidedignos, assim como a modelagem do banco de baterias e dos veículos elétricos.

As redes neurais, ferramenta baseada no conceito de aprendizagem de máquina, amplamente utilizada nos desafios atuais da sociedade, foram treinadas para a predição de potência das fontes de energia limpa e obtiveram eficiência de 94,04% e 92,9%, respectivamente para a potência solar e eólica.

Em adição às contribuições deste trabalho, destaca-se a possibilidade de, em trabalhos futuros, serem realizadas otimizações multi-objetivo do estacionamento inteligente, adicionando o planejamento energético do banco de baterias à solução do otimizador. A análise financeira do estacionamento inteligente sem o banco de baterias também é interessante para justificar sua implementação, assim como a comparação de resultados para diferentes demandas.

Devido à modelagem matemática desta solução ser composta pelo estado de fluxo de potência dos PEV – ‘0’, ‘1’ e ‘2’ – avalia-se também que a utilização de um otimizador que tenha sua arquitetura baseada em números inteiros seja válida para comparação com o resultado obtido com o GSA.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDELAZIZ, A. Y.; HEGAZY, Y. G.; EL-KHATTAM, W.; OTHMAN, M. M. Optimal allocation of stochastically dependent renewable energy based distributed generators in unbalanced distribution networks. **Electric Power Systems Research**, v. 119, n. 55, p. 34-44, 2015.

ALVES, M. A.; ALMEIDA, L. V.; REZENDE, T. M.; SILVA, P.; SEVERIANO, C. A.; SILVA, R.; GUIMARÃES, F. G. Otimização Dinâmica Evolucionária para Despacho de Energia em uma Microrrede usando Veículos Elétricos. *In*: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 14., 2019, Ouro Preto. **Anais** [...]. Ouro Preto: 2019. Disponível em: https://proceedings.science/sbai-2019/papers/otimizacao-dinamica-evolucionaria-para-despacho-de-energia-em-uma-microrrede-usando-veiculos-eletricos. Acesso em: 02 dez. 2020.

ASMUS, P. Microgrids, virtual power plants and our distributed energy future. **The Electricity Journal**, v. 23, n. 10, p. 72-82, 2010.

BARRIOS, P. P. V. **Control and energy management system of microgrid using genetic algorithm**. 2015. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 2015.

BRASIL. Agência Nacional de Energia Elétrica. **Resolução Homologatória nº 2.589, de 6 de agosto de 2019**. Homologa o resultado da quinta Revisão Tarifária Periódica – RTP – da EDP Espírito Santo Distribuição de Energia S.A., as Tarifas de Energia – TE e as Tarifas de Uso do Sistema de Distribuição – TUSD, e dá outras providências. Brasília, DF: ANEEL, 2019. Disponível em: http://www2.aneel.gov.br/cedoc/reh20192589ti.pdf. Acesso em: 19 nov. 2020.

BRASIL. Agência Nacional de Energia Elétrica. **Resolução Homologatória nº 2.749, de 6 de agosto de 2020**. Homologa o resultado do Reajuste Tarifário Anual de 2020, as Tarifas de Energia – TE e as Tarifas de Uso do Sistema de Distribuição – TUSD referentes à Espírito Santo Centrais Elétricas S/A. - EDP ES, e dá outras providências. Brasília, DF: ANEEL, 2020. Disponível em: http://www2.aneel.gov.br/cedoc/reh20202749ti.pdf. Acesso em: 19 nov. 2020.

CANADIAN SOLAR. **Canadian Solar Datasheet CS6P-260|265|270P**. 2019. Disponível em: https://s3.us-east 2.amazonaws.com/legacy.portalsolar.com.br/Content/EditorImages/files/Placa%20Solar%20Canadian%20Solar%20-%20Modelo%20CS6P-265P%20-%20265Watts.pdf. Acesso em: 17 nov. 2020.

CARNEIRO, J. **Módulos fotovoltaicos: características e associações**. 2010. Dissertação (Mestrado em Engenharia Elétrica) – Universidade do Minho, Guimarães, Portugal, 2010.

CARRILLO, C.; MONTAÑO A. F. O.; CIDRÁS J.; DÍAZ-DORADO E. Review of power curve modelling for wind turbines. **Renewable and Sustainable Energy Reviews**, v. 21, n. 4, p. 572-581, 2013.

CENTRO DE REFERÊNCIA PARA AS ENERGIAS SOLAR E EÓLICA SÉRGIO DE SALVO BRITO. **Tutorial de Energia Eólica**. 4 Tipos de aerogeradores para geração de energia elétrica. 2008. Disponível em: http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=231. Acesso em: 4 jul. 2019.

COELHO, V. N.; COELHO, I. M.; COELHO, B. N.; COHEN, M. W.; REIS, A. J.; SILVA, S. M.; SOUZA, M. J.; FLEMING, P. J.; GUIMARÃES, F. G. Multi-objective energy storage power dispatching using plug-in vehicles in a smart-microgrid. **Renewable Energy**, v. 89, n. 36, p. 730-742, 2016.

CENTRO DE REFERÊNCIA PARA AS ENERGIAS SOLAR E EÓLICA SÉRGIO DE SALVO BRITO. **Tutorial de Energia Solar Fotovoltaica**. 5 Módulos Fotovoltaicos. 2008. Disponível em: http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&catid=4. Acesso em: 4 jul. 2019.

ENERSUD. **Enersud Verne 555**. 2017. Disponível em: http://www.enersud.com.br/produtos/turbina-eolica-verne-555/. Acesso em: 17 nov. 2020.

FERREIRA, R. T. **Planejamento do carregamento de veículos elétricos atendidos por um eletroposto isolado**. 2018. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade do Espírito Santo, Vitória, 2018.

FIOROTTI, R. **Metodologia para Determinar a Potência Firme das Unidades de Geração Distribuída e sua Aplicação no Processo de Previsão de Demanda das Redes de Distribuição de Energia Elétrica**. 2015. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade do Espírito Santo, Vitória, 2015.

GATES NOTES. **COVID-19 is awful. Climate change could be worse**. 2020. Disponível em: https://www.gatesnotes.com/Energy/Climate-and-COVID-19. Acesso em: 29 set. 2020.

GATES NOTES. **How do we move around in a zero-carbon world?** 2020. Disponível em: https://www.gatesnotes.com/Energy/Moving-around-in-a-zero-carbon-world. Acesso em: 29 set. 2020.

GENSLER, A.; HENSE, J.; SICK, B.; RAABE, Nils. Deep Learning for solar power forecasting – An approach using AutoEncoder and LSTM Neural Network. *In*: INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS, 16., 2016, Budapest. **Proceedings** […]. Budapest: IEEE, 2016. p. 2858-2865.

GORBAN, A. N.; GORLOV, A. M.; SILANTYEV, V.M. Limits of the turbine efficiency for free fluid flow. **Journal of Energy Resources Technology**, v. 123, n. 4, p. 311-317, 2001.

HAYKIN, S. **Redes neurais artificiais:** princípios e prática. Porto Alegre: Bookman, 2001.

INTERNATIONAL ENERGY AGENCY. **CO2 Emissions from Fuel Combustion: Highlights**. Paris: IEA, 2019. Disponível em: https://webstore.iea.org/download/direct/2521?fileName=CO2_Emissions_from_Fuel_Combustion_2019_Highlights.pdf. Acesso em: 04 dez. 2020.

KATIRAEI, F.; IRAVANI, R.; HATZIARGYRIOU, N.; DIMEAS, A. Microgrids management: controls and operation aspects of microgrids. **IEEE Power & Energy Magazine**, v. 6, n. 3, p. 54-65, 2008.

LASSETER, R. H. MicroGrids. *In*: WINTER MEETING OF THE POWER ENGINEERING SOCIETY, 2., 2002, Nova Iorque. **Proceedings** […]. Nova Iorque: IEEE, 2002. v. 3, n. 1, p. 305-308.

LOPES, M. E. C. **Otimização do carregamento de veículos elétricos em ambientes privados.** 2016. Dissertação (Mestrado em Ciências da Engenharia e Tecnologias) – Programa de Pós-Graduação em Engenharia Eletrotécnica e de Computadores, Universidade do Porto, Porto, 2016.

LOPEZ, R. A. **Energia eólica**. São Paulo: Artliber Editora, 2002. 155 p.

MARQUES, V. C. **Modelagem de painel fotovoltaico submetido a sombreamento e conectado à rede elétrica monofásica**. 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal da Paraíba, João Pessoa, 2017.

MINISTÉRIO DE MINAS E ENERGIA. **Resenha Energética Brasileira 2020** – ano base 2019. Brasília, DF: MINISTÉRIO DE MINAS E ENERGIA, 2020. Disponível em: http://www.mme.gov.br/documents/36208/948169/Resenha+Energ%C3%A9tica+Brasileira+-+edi%C3%A7%C3%A3o+2020/ab9143cc-b702-3700-d83a-65e76dc87a9e. Acesso em: 04 dez. 2020.

MOKRYANI, G.; SIANO P. Combined Monte Carlo simulation and OPF for wind turbines integration into distribution networks. **Electric Power Systems Research**, v. 103, n. 11, p. 37-48, 2013.

NASCIMENTO, A. L. **Proposta de uma matriz energética para o Centro Tecnológico II**. 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal do Espírito Santo, Vitória, 2014.

NASSAR, A. M.; MAHMOUD, K. Accurate photovoltaic power forecasting models using deep LSTM-RNN. **Neural Computing and Applications**. v. 54, n. 1, p. 27-41, 2019.

NEILL, S. P.; HASHEMI, M. R. **Fundamentals of Ocean Renewable Energy**. Bangor: Academic Press, 2018. 336 p.

OSORIO, V. A. G.; MEDINA, A. C. R.; MELO, J. D.; FELTRIN, A. P. Optimal charging of electrical vehicles considering constraints of medium voltage distribution network. *In*: CONFERENCE ON INNOVATIVE SMART GRID TECHNOLOGIES, 13., 2013, São Paulo. **Proceedings** […]. São Paulo: IEEE, 2013. p. 1-7.

PINHO, J. T.; GALDINO, M. A. **Manual de Engenharia para Sistemas Fotovoltaicos**. Rio de Janeiro: Centro de Referência para as Energias Solar e Eólica Sergio de Salvo Brito, 2014.

QUOC, D. P.; CHAN, V. N.; DINH, T. N.; THE, T. N. Optimal design combined with power management for stand-alone microgrid. *In*: REGION 10 CONFERENCE TENCON, 10., 2016, Singapura. **Proceedings** […]. Singapura: IEEE, 2016. p. 1450-1455.
RASHEDI, E.; POUR, H. N.; SARYAZDI, S. GSA: a gravitational search algorithm. **Information Sciences**, v. 179, n. 5, p. 2232-2248, 2009.

RICHARDSON, P.; FLYNN, D.; KEANE, A. Optimal charging of electric vehicles in low-voltage distribution systems. **IEEE Transactions on Power Systems**, v. 27, n. 5, p. 268-279, 2012.

SABRI, M. N.; PUTEH, M.; RUSOP, M. An overview of Gravitational Search Algorithm utilization in optimization problems. *In*: INTERNATIONAL CONFERENCE ON SYSTEM ENGENEERING AND TECHNOLOGY, 13., 2013, Shah Alam. **Proceedings** […]. Shah Alam: IEEE, 2013. p. 61-65.

SEGURO, J. V.; LAMBERT, T. W. Modern estimation of the parameters of the Weibull wind speed distribution for wind energy analysis. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 85, n. 43, 2000.

SILVA, F. L. **Análise do Desempenho de uma Microrrede com Múltiplas Unidades de Geração Distribuída**. 2011. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo, Vitória, 2011.

SLOOTWEG, J. G. **Wind power modeling and impact on power systems dynamics**. 2003. Tese (Doutorado em Engenharia Elétrica) – Delft University of Technology, Delft, 2003.

SOUZA, J. P. **Módulos fotovoltaicos – perdas por mismatch em sistemas fotovoltaicos**. Rio Preto: Ecori Energia Solar, 2019. Disponível em: https://www.ecorienergiasolar.com.br/artigo/modulos-fotovoltaicos---perdas-por-mismatch-em-sistemas-fotovoltaicos. Acesso em: 17 nov. 2020.

TESLA. **Tesla Powerwall 2 Datasheet.** 2019. Disponível em: https://www.tesla.com/sites/default/files/pdfs/powerwall/Powerwall%202_AC_Datasheet_en_northamerica.pdf. Acesso em: 17 nov. 2020.

WANG, K.; QI, X.; LIU, H. Photovoltaic power forecasting based LSTM-convolutional network. **Energy**, v. 189, n. 116, p. 1-11, 2019.

WANG, T. H.; HONG, Y. W. P. Learning based energy management policy with battery dept-of-discharge considerations. *In*: GLOBAL CONFERENCE ON SIGNAL AND INFORMATION PROCESSING, 15., 2015, Orlando. **Proceedings** […]. Orlando: IEEE, 2015. p. 992-996.

ZHAO, M.; LIU, W.; SU J.; ZHAO, L.; DONG, X. Medium and long term load forecasting method for distribution network with high penetration DGs. *In*: CHINA INTERNATIONAL

CONFERENCE ON ELECTRICITY DISTRIBUTION, 14., 2014, Shenzhen. **Proceedings** […]. Shenzhen: IEEE, 2014. p. 442-444.